



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

POKROČILÉ SKÓROVÁNÍ SPÁNKOVÝCH DAT

ADVANCED SCORING OF SLEEP DATA

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Petra Jagošová

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Marina Ronzhina, Ph.D.

BRNO 2021

Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Bc. Petra Jagošová

ID: 195186

Ročník: 2

Akademický rok: 2020/21

NÁZEV TÉMATU:

Pokročilé skórování spánkových dat

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši v oblasti využití jednoduše měřitelných biosignálů (např. EKG, data z akcelerometru, fotopletysmografická křivka, aj.) pro hodnocení kvality spánku. Popište metriky pro hodnocení kvality spánku a konkrétní metody zpracování a analýzy dat používané v této oblasti. Zaměřte se na moderní techniky založené na hlubokém učení (např. umělá síť s konvolučními vrstvami či LSTM vrstvami, apod.). U jednotlivých metod uveďte jejich výhody/nevýhody v porovnání s konvenčním PSG přístupem. 2) Využijte veřejně dostupné databáze spánkových dat a vytvořte dvě množiny dat vhodné pro trénování a testování klasifikačních algoritmů. 3) Navrhněte a implementujte ve vhodném programovém prostředí postup pro analýzu a klasifikaci vybraných signálů. 4) Otestujte navrženou metodu na reálných záznamech a statisticky vyhodnoťte její účinnost. 5) Na základě předchozího bodu proveďte optimalizaci klasifikátoru pro dosažení co nejlepších výsledků. 6) Dosažené výsledky vhodně interpretujte. Například popište, ve kterých případech metoda chybovala a proč. Porovnejte dosažené výsledky s dostupnými údaji z literatury. Diskutujte výhody/nevýhody a možnosti vylepšení navrženého postupu.

DOPORUČENÁ LITERATURA:

- [1] ZAMBOTTI, M., et al. Wearable sleep technology in clinical and research settings. *Med Sci Sports Exerc*, 2019, vol. 51, pp 1538-1557.
- [2] FIORILLO, L., et al. Automated sleep scoring: a review of the latest approaches. *Sleep Medicine Reviews*, 2019, vol. 48, 101204, pp 1-12.

Termín zadání: 8.2.2021

Termín odevzdání: 21.5.2021

Vedoucí práce: Ing. Marina Ronzhina, Ph.D.

prof. Ing. Ivo Provazník, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Abstrakt

Tato diplomová práce se zabývá pokročilým skórováním spánkových dat, které bylo provedeno pomocí hluboké neuronové sítě. Ke skórování jsou využívána data tepové frekvence a informace o pohybu naměřené pomocí chytrých hodinek Apple Watch. Po vhodném předzpracování sloužila tato data jako vstupní parametry do navržených sítí. Cílem LSTM sítě bylo provést klasifikaci dat buď do dvou skupin na spánek a bdění nebo do tří skupin na bdění, Non-REM a REM. Nejlepších výsledků dosáhla síť provádějící klasifikaci spánek vs. bdění s využitím akcelerometru. Statistické vyhodnocení této nejlepší sítě dosáhlo hodnoty senzitivity 71,06 %, specifity 57,05 %, celkové úspěšnosti (accuracy) 70,01 % a F1 skóre 81,42 %.

Klíčová slova

Polysomnografie, klasifikace, chytré hodinky, tepová frekvence, akcelerometr, bdění, spánek, NREM, REM, hluboké učení, LSTM

Abstract

The master's thesis is focused on advanced scoring of sleep data, which was performed using deep neural network. Heart rate data and the movement information were used for scoring measured using an Apple Watch smartwatch. After appropriate pre-processing, this data serves as input parameters to the designed networks. The goal of the LSTM network was to classify data into either two groups for sleep and wake or into three groups for wake, Non-REM and REM. The best results were achieved by network doing classification of sleep vs. wake using the accelerometer. The statistical evaluation of this best-designed network reached the values of sensitivity 71,06 %, specificity 57,05 %, accuracy 70,01 % and F1 score 81,42 %.

Keywords

Polysomnography, classification, smartwatch, heart rate, accelerometer, wake, sleep, NREM, REM, deep learning, LSTM

Bibliografická citace

JAGOŠOVÁ, Petra. *Pokročilé skórování spánkových dat* [online]. Brno, 2021 [cit. 2021-05-19]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/134427>. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Marina Ronzhina.

Prohlášení autora o původnosti díla

Jméno a příjmení studenta:	<i>Bc. Petra Jagošová</i>
VUT ID studenta:	<i>195186</i>
Typ práce:	<i>Diplomová práce</i>
Akademický rok:	<i>2020/2021</i>
Téma závěrečné práce:	<i>Pokročilé skórování spánkových dat</i>

Prohlašuji, že svou závěrečnou práci jsem vypracovala samostatně pod vedením vedoucí závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědoma následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne: 19. května 2021

podpis autora

Poděkování

Děkuji vedoucí diplomové práce Ing. Marině Ronzhině, Ph.D. za trpělivost, vstřícnost, účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne: 19. května 2021

podpis autora

Obsah

SEZNAM OBRÁZKŮ	8
SEZNAM TABULEK.....	10
ÚVOD	11
1. HODNOCENÍ SPÁNKOVÝCH DAT	12
1.1 STANDARDNÍ KLINICKÉ POSTUPY	12
1.2 MODERNÍ POSTUPY VYUŽÍVAJÍCÍ BIOMEDICÍNSKÝCH SIGNÁLŮ	14
1.2.1 <i>Hodnocení pohybové aktivity</i>	15
1.2.2 <i>Hodnocení srdečního rytmu</i>	16
2. DATABÁZE SPÁNKOVÝCH SIGNÁLŮ	18
3. HLUBOKÉ UČENÍ.....	19
3.1 MĚLKÁ UMĚLÁ NEURONOVÁ SÍŤ	20
3.2 KONVOLUČNÍ NEURONOVÁ SÍŤ	22
3.2.1 <i>1D konvoluční neuronová síť</i>	25
3.3 REKURENTNÍ NEURONOVÁ SÍŤ.....	26
3.3.1 <i>LSTM síť</i>	26
3.4 PŘEHLED POUŽÍVANÝCH KLASIFIKAČNÍCH METOD	28
4. NAVRŽENÝ POSTUP KLASIFIKACE.....	29
4.1 SPÁNKOVÁ DATA NAMĚŘENÁ APPLE WATCH	30
4.2 PŘEDZPRACOVÁNÍ DAT.....	33
4.3 STATISTICKÉ VYHODNOCENÍ VÝSLEDKŮ	38
4.4 KLASIFIKACE SPÁNKOVÝCH STÁDIÍ	40
4.4.1 <i>Klasifikace spánek vs. bdění s využitím tepové frekvence</i>	40
4.4.2 <i>Klasifikace spánek vs. bdění s využitím akcelerometru</i>	44
4.4.3 <i>Klasifikace spánek vs. bdění s využitím tepové frekvence a akcelerometru</i>	46
4.4.4 <i>Klasifikace na bdění vs. NREM vs. REM s využitím tepové frekvence</i>	50
4.4.5 <i>Klasifikace na bdění vs. NREM vs. REM s využitím akcelerometru</i>	53
4.4.6 <i>Klasifikace na bdění vs. NREM vs. REM s využitím tepové frekvence a akcelerometru</i>	57
5. ZHODNOCENÍ VÝSLEDKŮ	60
6. ZÁVĚR.....	64
LITERATURA.....	65
SEZNAM SYMBOLŮ A ZKRATEK	69
SEZNAM PŘÍLOH.....	70

SEZNAM OBRÁZKŮ

Obrázek 1 Příklad hypnogramu [3]	12
Obrázek 2 Ukázka zařízení Muse 2 [7]	14
Obrázek 3 Příklad dat nasnímaných pomocí aktigrafu [12]	15
Obrázek 4 Příklad RR intervalu [13]	16
Obrázek 5 Grafické znázornění použité architektury LSTM	19
Obrázek 6 Biologický neuron [25]	20
Obrázek 7 Umělý neuron [26]	21
Obrázek 8 Vícevrstevná dopředná neuronová síť [26]	21
Obrázek 9 Schéma konvoluční neuronové sítě [27]	22
Obrázek 10 Ukázka konvoluce [28]	22
Obrázek 11 Funkce sigmoid a RELU [30]	23
Obrázek 12 Příklad max pooling a average pooling [27]	24
Obrázek 13 Příklad plně propojené vrstvy [31]	24
Obrázek 14 Příklad aplikace dropoutu [32]	25
Obrázek 15 Schéma architektury 1D CNN [33]	25
Obrázek 16 Grafické znázornění RNN [35]	26
Obrázek 17 Opakující se modul v LSTM [35]	27
Obrázek 18 Schéma navrženého postupu	29
Obrázek 19 Ukázka akcelerometrických dat	32
Obrázek 20 Ukázka dat naměřených pomocí PPG senzoru	32
Obrázek 21 Ukázka upraveného hypnogramu	33
Obrázek 22 Ukázka epochy s chybějícími hodnotami	34
Obrázek 23 Ukázka interpolace epochy s původním počtem 300 hodnot	35
Obrázek 24 Ukázka upravených dat z akcelerometru	35
Obrázek 25 Ukázka autoenkodéru pro extrakci vektoru délky 30	36
Obrázek 26 Ukázka neúplných dat	37
Obrázek 27 Ukázka kompletního hypnogramu neúplného záznamu tepové frekvence a akcelerometru (viz. obrázek 26)	37
Obrázek 28 Ukázka dat tepové frekvence po standardizaci	38
Obrázek 29 Matice záměn pro klasifikaci do dvou kategorií [38]	38
Obrázek 30 Grafické znázornění použité architektury LSTM modelu 1	40
Obrázek 31 Výsledek klasifikace pro testovací data modelu 1 na čtyřech záznamech	42
Obrázek 32 Výsledek klasifikace pro testovací data modelu 1 pro 1 záznam	43
Obrázek 33 Výsledek klasifikace pro testovací data modelu 1 pro 1 záznam	43
Obrázek 34 Grafické znázornění použité architektury LSTM modelu 2	44
Obrázek 35 Průběh učení modelu 2	45
Obrázek 36 Grafické znázornění použité architektury LSTM modelu 3	46
Obrázek 37 Graf zobrazující průběhy normalizovaných akcelerometrických dat (skutečné/predikované fáze, w – bdělost, s – spánek)	47
Obrázek 38 Graf zobrazující průběhy normalizované tepové frekvence (skutečné/predikované fáze, w – bdělost, s – spánek)	48
Obrázek 39 Výsledek klasifikace pro testovací data modelu 3 pro 5 záznamů	49
Obrázek 40 Grafické znázornění použité architektury LSTM modelu 4	50
Obrázek 41 Výsledek klasifikace pro testovací data modelu 4	52
Obrázek 42 Grafické znázornění použité architektury LSTM modelu 5	53
Obrázek 43 Průběh učení modelu 5	54

Obrázek 44 Graf zobrazující průběhy normalizovaného akcelerometru (skutečné/predikované fáze, w – bdělost, NREM – Non REM)	55
Obrázek 45 Grafické znázornění použité architektury LSTM modelu 6	57
Obrázek 46 Graf zobrazující průběhy normalizovaného akcelerometru (skutečné/predikované fáze, w – bdělost, NREM – Non REM)	59
Obrázek 47 Výsledek klasifikace pro testovací data na modelu 1 pro šest záznamů	71
Obrázek 48 Výsledek klasifikace pro testovací data modelu 1 pro 1 záznam	71
Obrázek 49 Výsledek klasifikace pro testovací data modelu 1 pro 1 záznam	72
Obrázek 50 Výsledek klasifikace pro testovací data modelu 1 pro 1 záznam	72
Obrázek 51 Průběh učení modelu 3	73
Obrázek 52 Výsledek klasifikace pro testovací data modelu 3 pro všechny záznamy	73
Obrázek 53 Výsledek klasifikace pro testovací data modelu 5	75

SEZNAM TABULEK

Tabulka 1 Přehled vybraných studií	28
Tabulka 2 Shrnutí údajů o datech	31
Tabulka 3 Matice záměn trénovacích dat – model 1	41
Tabulka 4 Matice záměn testovacích dat – model 1	41
Tabulka 5 Statistické vyhodnocení modelu 1	42
Tabulka 6 Matice záměn testovacích dat – model 2	45
Tabulka 7 Statistické vyhodnocení modelu 2	46
Tabulka 8 Matice záměn testovacích dat 6 záznamů – model 3	48
Tabulka 9 Matice záměn testovacích dat 5 záznamů – model 3	49
Tabulka 10 Statistické vyhodnocení modelu 3	50
Tabulka 11 Matice záměn trénovacích dat – model 4	51
Tabulka 12 Matice záměn testovacích dat – model 4	51
Tabulka 13 Statistické vyhodnocení modelu 4	52
Tabulka 14 Matice záměn trénovacích dat – model 5	55
Tabulka 15 Matice záměn testovacích dat – model 5	56
Tabulka 16 Statistické vyhodnocení modelu 5	56
Tabulka 17 Matice záměn trénovacích dat – model 6	58
Tabulka 18 Matice záměn testovacích dat – model 6	58
Tabulka 19 Statistické vyhodnocení modelu 6	59
Tabulka 20 Porovnání výsledků klasifikace spánků vs. bdění	61
Tabulka 21 Porovnání výsledků klasifikace bdění vs. NREM vs. REM	62
Tabulka 22 Statistické vyhodnocení modelu 4 - bdění	74
Tabulka 23 Statistické vyhodnocení modelu 4 - NREM	74
Tabulka 24 Statistické vyhodnocení modelu 4 - REM	74
Tabulka 25 Statistické vyhodnocení modelu 5 - bdění	75
Tabulka 26 Statistické vyhodnocení modelu 5 - NREM	75
Tabulka 27 Statistické vyhodnocení modelu 5 - REM	76
Tabulka 28 Statistické vyhodnocení modelu 6 - bdění	76
Tabulka 29 Statistické vyhodnocení modelu 6 - NREM	76
Tabulka 30 Statistické vyhodnocení modelu 6 - REM	77

ÚVOD

Spánek hraje velmi důležitou roli v životě člověka, je důležitý pro jeho psychické i fyzické zdraví. Je tedy potřeba, aby spánek byl dostatečně dlouhý a kvalitní. Setkáváme se však s velkým množstvím chorob, které postihují velké množství lidí. Tyto choroby jsou často spojeny se špatnou kvalitou spánku. Proto analýza a hodnocení kvality spánku nabývá stále větší významnosti.

Zlatým standardem pro klinické hodnocení spánku a spánkových poruch je polysomnografie. Vyšetření probíhá ve spánkové laboratoři po celou noc, kdy je snímána řada biosignálů. Jednou z nevýhod je, že u vyšetření musí být přítomen odborný personál. Další nevýhodou je, že vyšetření se provádí pouze ve specializované laboratoři s odpovídajícím vybavením. Kvůli značnému množství senzorů může být vyšetření pro řadu pacientů nekomfortní a psychicky náročné. Namísto vyšetření ve spánkové laboratoři je možné využít speciální přenosné systémy, které umožňují zaznamenání polysomnografických dat. Nicméně použití těchto systémů je velmi drahé a není vhodné pro dlouhodobější monitorování. V současné době roste snaha o nalezení moderních metod, které by umožnily zaznamenávání potřebných údajů z pohodlí domova. Jedná se o moderní zařízení umožňující snímat signály z lidského těla. V ideálním případě nejsou zařízení moc velká a obsahují co nejméně senzorů, a tím zajišťují uživateli pohodlí. Jedním z příkladů zařízení tohoto typu je čelenka Muse, která snímá mozkovou aktivitu. Jako další příklad lze uvést náramková zařízení jako jsou chytré hodinky nebo aktigrafický náramek.

Celonoční polysomnografické záznamy jsou běžně vizuálně hodnoceny odborníky. Proces hodnocení je velmi zdoluhavý a náročný, jelikož jsou jednotlivé 30-sekundové epochy samostatně hodnoceny. Usnadnění hodnotícího procesu je velmi aktuálním tématem dnešní doby. Spočívá v rozvoji a zlepšování metod pro automatickou klasifikaci spánkových fází. Automatická klasifikace je prováděna například pomocí moderních metod založených na hlubokých neuronových sítích.

V této diplomové práci byl použitý moderní postup pro hodnocení kvality spánku místo polysomnografického vyšetření. Data použitá v této práci pochází z americké studie a byla naměřená pomocí chytrých hodinek Apple Watch. Výhodou je možnost dlouhodobého snímání dat s využitím jednoho zařízení připevněného na zápěstí.

Klasifikace spánkových fází je zde provedena v programovém prostředí MATLAB pomocí hluboké neuronové LSTM (Long Short Term Memory) sítě. V rámci klasifikace bylo vytvořeno šest modelů, které se liší použitým počtem příznaků a počtem klasifikačních skupin. Všechny modely obsahují grafickou reprezentaci své architektury a byly statisticky zhodnoceny pomocí matice záměn. Na závěr byly diskutovány výhody a nevýhody použitých dat, klasifikační sítě a porovnání získaných výsledků s publikovanými studiemi.

1. HODNOCENÍ SPÁNKOVÝCH DAT

Kvalitní spánek je důležitou součástí našeho života. Jeho poruchy tvoří významné zdravotní problémy jako nespavost, narkolepsie nebo spánková apnoe. V současné době narůstá počet lidí se spánkovými poruchami, kteří vyhledávají lékařskou pomoc. [1] [2]

1.1 Standardní klinické postupy


Polysomnografie (PSG) je zlatým standardem pro klinické hodnocení spánku a spánkových poruch. PSG vyšetření se provádí po celou noc ve spánkové laboratoři. Během vyšetření je zaznamenáváno několik parametrů, mezi ně řadíme například krevní tlak, elektrokardiogram (EKG) nebo dýchací pohyby. Základními měřenými signály jsou elektroencefalogram (EEG), elektrookulogram (EOG) a elektromyogram svalů brady (EMG).

Elektroencefalografie snímá a zaznamenává elektrickou aktivitu mozku. Mezinárodní systém definuje rozmístění elektrod (celkem 21) během vyšetření, tzv. systém 10-20. Systém se používá proto, aby při opakovaném vyšetření došlo k umístění elektrod na stejné místo.

Elektrookulografie snímá elektrickou aktivitu očních pohybů. Jde o měření změn elektrického potenciálu pomocí elektrod umístěných okolo očí.

Elektromyografie analyzuje a zaznamenává signály vznikající činností kosterního svalstva. Při PSG vyšetření je měřeno submentální EMG (subEMG) a dolní části nohou. SubEMG je neinvazivní snímání pohybů brady. [3]

Klasifikace spánku se provádí podle manuálu Americké akademie spánkové medicíny (AASM). Od roku 2007 je AASM uznávaným standardem pro hodnocení polysomnografického záznamu. Hodnocení spánkových stádií se provádí po epochách, jejichž délka je 30 sekund. Výsledkem hodnocení je hypnogram (viz. obrázek 1), graf zobrazující jednotlivé spánkové fáze. AASM standard rozděluje spánek do 5 stádií. [4]



Obrázek 1 Příklad hypnogramu [3]

Rozdělení spánkových fází podle AASM standardu [1]:

- **Wake fáze (W)** je stav bdělosti, kdy si plně uvědomujeme své okolí. Ve wake fázi je v EEG charakteristická přítomností alfa rytmu. Mohou se zde vyskytovat například rychlé oční pohyby nebo aktivita svalů brady.
- **Non-REM 1 (N1)** jedná se o fázi přechodu mezi spánkem a bděním, kdy lze velmi jednoduše člověka probudit. Vyskytují se zde pomalé oční pohyby, svalová aktivita se snižuje. N1 fáze trvá přibližně 4 – 8 minut.
- **Non-REM 2 (N2)** tvoří téměř 50 % celkové doby spánku. V N2 fázi se typicky vyskytují K-komplexy a spánková vřetena. Svalová aktivita se snižuje a nedochází k výskytu očních pohybů.
- **Non-REM 3 (N3)** je fáze hlubokého spánku. V EEG jsou přítomné delta vlny, které mají nízkou úroveň a frekvenci. Svalová aktivita je nízká a oční bulvy se nepohybují.
- **REM fáze (Rapid Eye Movement)** je část spánku, během které se zdají sny. Vyznačuje se rychlými očními pohyby a vysokou aktivitou mozku. REM fáze obvykle tvoří 20 – 25 % celkové doby spánku.

Manuální hodnocení spánkových fází je časově velmi náročné. Polysomnografická data jsou odborníkem hodnocena vizuálně. Celonoční záznamy jsou rozděleny na jednotlivé epochy, kterým je následně přiřazena daná spánková fáze. Hlavní nevýhodou manuálního hodnocení je velká časová náročnost nutná k vyhodnocení spánkových dat. Další nevýhodou tvoří omezení možnosti provedení vyšetření. To je možné ve specializované spánkové laboratoři, kde je nutné mít k dispozici speciální vybavení a odborný personál. Existují i přenosné systémy pro získání polysomnografických dat. Avšak jejich použití je velmi drahé a není vhodné pro dlouhodobější monitorování. [5] [6]

Použití polysomnografie, která je vícekanálová, předkládá lepší výsledky klasifikace, avšak obsahuje více vodičů a senzorů, které mohou ovlivnit spánek pacientů. Na rozdíl od vícekanálových přístupů je jednocanálové EEG možným řešením pro domácí monitorování spánku. Příkladem takového zařízení je Muse. Jedná se o elektroencefalografické zařízení, které je celosvětově používané vědci v oblasti neurověd. Zařízení je vlastně pohodlná čelenka, která snímá mozkovou aktivitu. Muse nabízí statistiky sledování spánku, včetně vizualizace spánkových fází, sledování polohy spánku a skóre účinnosti spánku. Na obrázku 2 je zobrazeno zařízení Muse 2, které

umožňuje měření EEG signálů ze čtyř míst na hlavě. Dále umožňuje snímat a zobrazit srdeční činnost, pomocí měření srdečního PPG pulsu nasnímaného z čela, dechovou činnost a stabilitu a pozici těla, ke kterým využívá gyroskopů. [7]



Obrázek 2 Ukázka zařízení Muse 2 [7]

V současné době roste snaha o nalezení a zlepšení automatických metod, které by usnadnily práci odborníkům. Avšak nalezení správné metody pro klasifikaci spánkových fází není vůbec jednoduché. Spolu s automatickou klasifikací jsou hledány další vyšetřovací metody pro hodnocení spánku. PSG vyšetření je neinvazivní, ale je během něj využíváno velké množství senzorů, což není zcela komfortní. Dále samotný pobyt ve spánkové laboratoři může pacienty rozrušit, čímž může dojít k získání nerelevantních dat. Snímání biomedicínských signálů z lidského těla, například pomocí chytrých hodinek, by mělo být dlouhodobě proveditelné z domova, nemělo by zatěžovat pacienta přílišným množstvím senzorů a přístrojů. [5] [8]

1.2 Moderní postupy využívající biomedicínských signálů

Sledování parametrů informujících o úrovni pohybu, tepové frekvenci, příjmu potravy, spálených kaloriích a dalších, se stalo oblíbenou součástí monitorování zdraví života spotřebitelů. Moderní zařízení dokážou snímat signály z těla, tzv. jednoduše měřitelné signály. Z klinického hlediska má většina těchto signálů velký potenciál. Například pro hodnocení spánku ve spánkových studiích je čím dál více využíváno aktigrafické vyšetřovací metody nebo signálů tepové frekvence. Mezi nejběžněji používané signály řadíme akcelerometrická data, pletysmografickou křivku, měření tepové frekvence a další. [9]


1.2.1 Hodnocení pohybové aktivity

Aktigrafie je vyšetřovací metoda vhodná pro hodnocení spánku, která je stále více využívána ve spánkových studiích. Aktigrafická zařízení, náramky, jsou nejčastěji umístěna na zápěstí nedominantní ruky. Jedná se o monitorování pohybové aktivity snímané pomocí akcelerometru. Ten detekuje pohyb ve více směrech, například ve třech osách. Pohyb je následně převeden na digitální signál, který se používá k vyhodnocení počtu pohybů. Výstupem měření je zobrazení počtu pohybů ve zvolených intervalech. V závislosti na zvoleném prahu algoritmu dojde k zatřídění epochy na spánek nebo bdění. Předpokladem určení spánku jsou žádné pohyby, nebo je jich tak málo, že nepřesáhnou prahovou hodnotu. Naproti tomu u stavu bdělosti je přítomno více pohybů.

Výhodou je, že pomocí aktigrafie jsou data pohodlně zaznamenávána. Díky dostatku paměti monitorování probíhá nepřetržitě 24 hodin denně, po dobu několika dní až týdnů. Je neinvazivní, má snadnější použití a je podstatně levnější ve srovnání s polysomnografií. Pro pacienty obávající se z pobytu ve spánkové laboratoři může představovat příjemnější alternativu vyšetření.

Největší nevýhodou hodnocení spánku pomocí aktigrafie představuje velmi nízká hodnota specifity. Příkladem problému je nesnadné odlišení odpočinkových činností jako je čtení nebo sledování televize od spaní. Společným rysem těchto aktivit je malý či téměř žádný pohyb. Některá aktigrafická zařízení jsou vybavena světelnými senzory, které například zaznamenají čas zhasnutí světel. Pomocí světelných senzorů je možné rozlišit mezi denním odpočinkem a zhasnutím světel před spaním.

Aktigrafie je často využívána ve studiích zkoumajících poruchy spánku. Používá se jako alternativa k PSG, slouží pro doplňující monitorování nebo pro následné pozorování. Velmi důležitou úlohu hraje při sledování cirkadiálních rytmů, kdy je téměř nemožné získat 24 - hodinový nebo delší záznam PSG. [8] [10] [11]




Obrázek 3 Příklad dat nasnímaných pomocí aktigrafu [12]

Obrázek 3 zobrazuje příklad ohodnocených dat nasnímaných pomocí aktigrafu. Osa x zachycuje čas v průběhu 24 hodin. Osa y představuje dny v týdnu, konkrétně pátek až pondělí. Černé čáry symbolizují úroveň aktivity, červené čáry označují bdělost a žluté čáry představují úroveň světla. Modré oblasti znázorňují dobu spánku. [12]

1.2.2 Hodnocení srdečního rytmu

Pro automatickou klasifikaci spánkových fází lze použít variabilitu srdečního rytmu namísto polysomnografie. Jedná se o levnou, neinvazivní alternativu, která poskytuje nenápadné a dlouhodobé monitorování spánku z pohodlí domova. Ve srovnání s polysomnografickým vyšetřením, které je omezeno nutností měření ve spánkové laboratoři.

Variabilita srdečního rytmu (HRV) se mění s fázemi spánku. Je odrazem mnoha fyziologických faktorů, které regulují normální srdeční rytmus. Jedná se o aktivitu sinusového uzlu, jednoduše jde o měření časového kolísání mezi údery srdce. HRV umožňuje posoudit stav autonomního nervového systému, který reguluje srdeční činnost. Srdeční frekvence se počítá jako vzdálenost mezi komplexy QRS. Hlavní informace, která popisuje variabilitu srdečního rytmu je naměřená posloupnost RR intervalů (viz. obrázek 4). Jako RR intervaly označujeme vzdálenosti mezi sousedními R vlnami. Dalším označením jsou NN intervaly, tzv. normal-to-normal. Označují po sobě jdoucí QRS komplexy, před kterými se vyskytuje P vlna.



Obrázek 4 Příklad RR intervalu [13]

Signál HRV je generován ze signálu EKG. Záznamy mohou být snímány krátkodobě (v řádech minut) nebo dlouhodobě (např. Holterovské monitorování signálu EKG). Monitorování srdeční aktivity v klinické praxi probíhá pomocí 12 - svodového zařízení. Tento systém měření nelze aplikovat v domácím prostředí. Existují však i zařízení, která pracují s menším počtem svodů. U těchto zařízení je třeba dbát na to, aby nedošlo ke ztrátě informací. Alternativním způsobem pro záznam EKG signálů je Holter. Jedná se nejčastěji o 2 – svodové zařízení, které po určitou dobu umožňuje zaznamenávat srdeční aktivitu. V současné době jsou velmi oblíbené chytré hodinky, které podporují monitorování srdeční frekvence. [9][11][14]

Pulzní oxymetrie je neinvazivní metoda, která měří nasycení krve kyslíkem. Jedná se o zařízení, které využívá světelný zdroj a fotodetektor. Při měření je využíváno dvou vlnových délek, v oblasti červené a infračervené. Měření se nejčastěji provádí na prstu nebo ušním lalůčku.

Fáze spánku jsou ovlivňovány regulací autonomního nervového systému. Způsobují změny v mnoha fyziologických parametrech. Během spánku dochází ke zpomalení metabolismu, který se projevuje snížením tepové frekvence, krevního tlaku a dechové frekvence. S příchodem hlubšího spánku, tepová frekvence klesá. Naproti tomu v REM fázi dochází k nárustu tepové frekvence.

Výhodou pulzní oxymetrie je neinvazivnost, nízká cena a jednoduchost použití. Nevýhodou je, že je velmi citlivá na pohybové artefakty, okolní světlo, anemii.

Autoři Ramiro Casal, et al., ve své studii vyvinuli algoritmus, který dokáže pouze s použitím signálů tepové frekvence a SpO2 (saturace kyslíku v krvi) získané z pulzní oxymetrie provést klasifikaci spánku na bdění a spánek. Autoři použili signály z datové sady SHLE (Sleep Heart Health Study), které byly naměřeny s odstupem několika let. Jednalo se o domácí polysomnografické záznamy, které byly pořízeny pod dohledem specializovaných techniků. Ve své studii autoři navrhli model hlubokého učení. Na testovacích datech dosáhli hodnoty senzitivity 94,13 % a specifity 85,26 %. [15]

2. DATABÁZE SPÁNKOVÝCH SIGNÁLŮ

The Montreal Archive of Sleep Studies (MASS) je otevřená a kolaborativní databáze laboratorních polysomnografických záznamů. Cílem MASS je poskytnout standartní a snadno přístupný zdroj dat pro srovnání různých systémů vyvinutých s cílem pomoci automatizaci analýzy spánku. Poskytuje také snadno dostupný zdroj dat pro rychlé ověření experimentálních výsledků a pro průzkumné analýzy. Jedná se o sdílený zdroj, který lze použít k podpoře rozsáhlé spolupráce při studiu spánku. MASS se skládá z kohort zahrnující podmnnožiny. Záznamy v rámci podmnnožin jsou co nejhomogennější, zatímco mezi podmnnožinami jsou heterogennější. [15]

Webové stránky *PhysioNet* nabízí bezplatný přístup přes web k velkým sbírkám fyziologických signálů a souvisejícímu open-source softwaru. *PhysioNet* byl založen v roce 1999 pod záštitou National Institutes of Health. Původním posláním bylo provádět a katalyzovat biomedicínský výzkum a vzdělání tím, že nabízí bezplatný přístup k velkým sbírkám fyziologických a klinických dat. *PhysioNet* má stránku, která zobrazuje abecední seznam všech databází. Ty jsou rozděleny podle různých přístupů (otevřený, omezený a ověřený přístup). [16]

Otevřený přístup

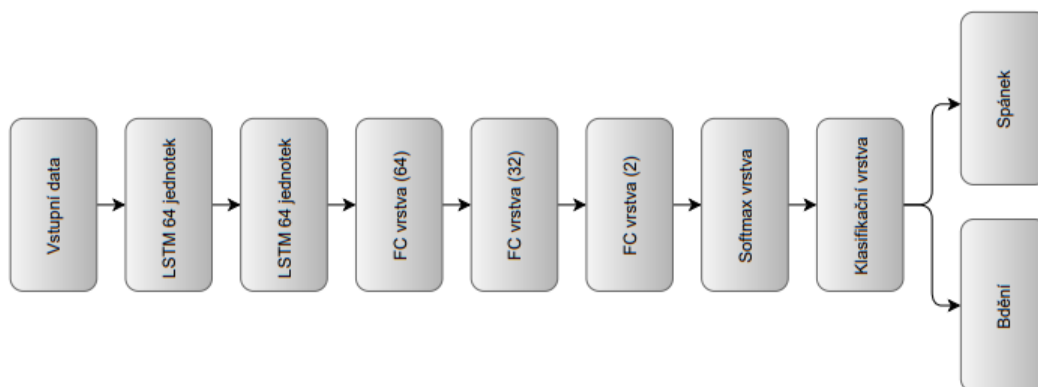
The sleep-edf database obsahuje 197 celonočních polysomnografických záznamů spánků. Ty obsahují EEG, EOG, EMG brady. Některé záznamy obsahují také záznamy dýchání a informace o tělesné teplotě. Hypnogramy byly ručně skórovány specialisty podle příručky Rechtschaffen a Kales. [17] [18]

Motion and heart rate from a wrist-worn wearable and labeled sleep from polysomnography obsahuje záznamy zrychlení a tepové frekvence zaznamenané pomocí chytrých hodinek Apple Watch. Obsahuje také ohodnocený celonoční polysomnografický záznam. Údaje byly sbírány na Univerzitě v Michiganu celkem od 31 osob. [17] [19]

Multilevel Monitoring of Activity and Sleep in Healthy People (MMASH) je soubor dat od 22 zdravých účastníků. Obsahuje nepřetržité 24 - hodinové záznamy o srdečním rytmu, tříosém akcelerometru, kvalitě spánku a psychologických charakteristikách (např. stav úzkosti, stresové události atd.). Datový soubor navíc obsahuje biomarkery slin a protokol aktivity. Soubor dat MMASH umožňuje vědcům otestovat korelace mezi fyzickou aktivitou, kvalitou spánku a psychologickými charakteristikami. [17] [20]

3. HLUBOKÉ UČENÍ

Jelikož je vizuální hodnocení spánkových fází časově velmi náročné, roste snaha o rozvoj a zlepšení metod, které slouží k automatické klasifikaci spánkových stádií. Avšak vytvoření správné metody není vůbec jednoduché, metoda musí dosahovat vysoké úspěšnosti, aby mohla být použita pro automatickou klasifikaci v lékařských zařízeních. Ke klasifikaci spánkových fází mohou být využity například algoritmy strojového učení. V této kapitole jsou popsány moderní techniky založené na hlubokém učení. Hluboké učení je metoda umělé inteligence, ve které je za pomoci mnohvrstevných nelineárních výpočetních modelů získána užitečná informace z dat. Architektura těchto modelů je založena na hlubokých neuronových sítích. V klasifikačních úlohách, kde je datům přiřazena klasifikační kategorie, dosahuje hluboké učení vysoké přesnosti. Long Short Term Memory neboli LSTM síť je navržena pro práci s 1D signály a časovými řadami. LSTM vrstva je RNN síť, která je schopna se naučit dlouhodobé závislosti v signálech, přesněji závislosti ze vzdálených časových kroků. Na obrázku 5 je ukázka použité LSTM architektury. [21]



Obrázek 5 Grafické znázornění použité architektury LSTM

Umělá inteligence je oblast, která zahrnuje strojové učení, hluboké učení a mnoho dalších přístupů. Vznikla v padesátých letech a jejím cílem bylo automatizovat úlohy, které jsou obvykle řešeny lidmi.


Strojové učení odkazuje na algoritmy, které se dokážou učit a k provedení úlohy je není třeba explicitně naprogramovat. Umělá inteligence nedokázala zjistit explicitní pravidla pro řešení komplikovanějších problémů. Strojové učení poskytuje systémům schopnost se automaticky učit, dochází ke zlepšení výkonu na základě získaných zkušeností a znalostí, aniž by došlo k přesnému naprogramování. Využívá se například ke klasifikaci obrazů, rozpoznání řeči, pro jazykový překlad a k řešení mnoha dalších problémů. Klasické programování má na vstupu zadaná pravidla a data, jejichž

výsledkem jsou odpovědi. Naopak vstupem strojového učení jsou data a odpovědi. Výsledkem jejich zpracování jsou pravidla, která mohou být aplikována na data nová.

Hluboké učení tvoří specifickou podskupinu strojového učení. Jedná se o přístup k učení se reprezentací z dat. Důraz klade na učení se následujících vrstev stále smysluplnějších reprezentací. Hluboké učení umožňuje modelu, aby se všechny vrstvy učily současně. Využívá vícevrstvé umělé neuronové sítě. Sítě jsou složeny ze vstupní vrstvy, po které následují skryté vrstvy, jejich počet se liší podle použité architektury, zakončení tvoří výstupní vrstva. Pojem hloubka modelu označuje počet automaticky se učících vrstev během procesu trénování. Zahrnuje desítky až stovky po sobě jdoucích vrstev, kdy se všechny učí automaticky při trénování. Tyto vrstvy upravují vstupní data, ze kterých dojde postupně k zisku výstupních dat. To, co dělá vrstva se svými vstupními daty, je uloženo ve váhách vrstvy. Váhy jsou někdy nazývány jako parametry vrstvy. Učení je řízeno ztrátovým skóre. Jedná se o vzdálenost mezi skutečným výstupem, který je známý a predikovaným výstupem, který byl získán jako výstup sítě. Toto skóre se používá jako zpětnovazební signál, podle kterého se upravují váhy ve směru, aby došlo ke snížení ztrátového skóre. Tuto úlohu vykonává optimalizátor. Výhodou hlubokého učení je, že usnadňuje řešení problémů, protože provádí automatizace, které jsou nejdůležitějším krokem v postupech strojového učení. [22]

3.1 Mělká umělá neuronová síť


Umělé neuronové sítě jsou inspirovány funkcí lidského mozku. Jejich struktura je podobná lidské nervové soustavě. Základním prvkem lidské je biologický neuron (viz. obrázek 6). Je složen z několika částí, a to z těla neuronu (tzv. soma), dendritů (vstupy neuronu), axon (výstup neuronu, je vždy jen jeden), synapse (jsou zakončení axonů, která slouží pro přenos informací mezi neurony). Neuron je specializovaná buňka určená k přenosu, zpracování a uchovávání informací. [23] [24]



Obrázek 6 Biologický neuron [25]


Základní stavební jednotkou umělých neuronových sítí je formální neuron (viz. obrázek 7), který vychází z biologického neuronu. Umělý neuron má n vstupů x_1, x_2, \dots, x_n , které modelují dendrity. Vstupy jsou váhovány vektorem koeficientů w_1, w_2, \dots, w_n , jsou to reálné synaptické váhy určující propustnost. Váhovaná suma vnitřních

hodnot znázorňuje vnitřní potenciál ξ . Po dosažení tzv. prahové hodnoty h indikuje hodnota potenciálu výstup neuronu y . [23][26]



Obrázek 7 Umělý neuron [26]

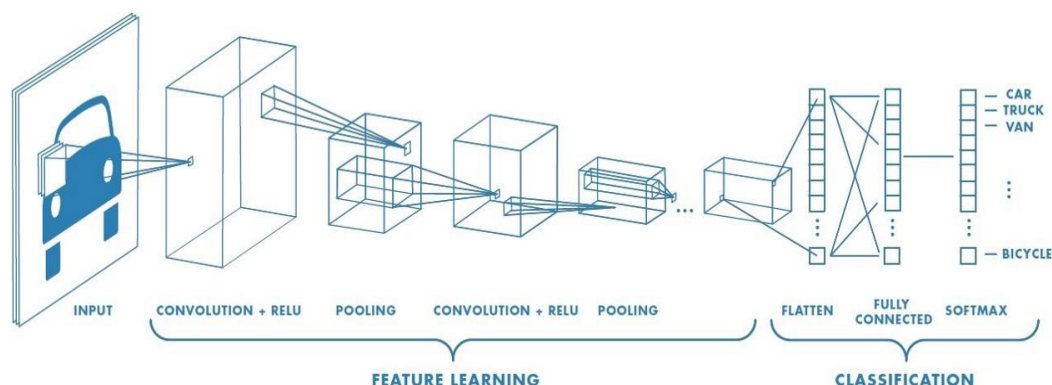
Umělá neuronová síť je složena z formálních neuronů, které jsou vzájemně propojeny a uspořádány do vrstev. Každý neuron v dané vrstvě je propojen se všemi neurony ve vrstvě následující. Architektura neuronové sítě je dána počtem neuronů a jejich vzájemným propojením v síti. Podle architektury dělíme neuronové sítě na dopředné a rekurentní. Neurony rozlišujeme na vstupní, skryté (pracovní) a výstupní. Všechny neuronové sítě jsou tvořeny minimálně vstupní a výstupní vrstvou. Skrytá vrstva přijímá signál ze vstupní vrstvy, který po zpracování posílá do výstupní vrstvy. Neuronové sítě mohou obsahovat několik skrytých vrstev. Na obrázku 8 je příklad dopředné neuronové sítě s více skrytými vrstvami. [26]



Obrázek 8 Vícevrstevná dopředná neuronová síť [26]

3.2 Konvoluční neuronová síť


Konvoluční neuronová síť neboli CNN jsou typem hlubokých neuronových sítí. Jedná se o dopřednou umělou neuronovou síť, která obsahuje konvoluční vrstvy. 2D CNN se nejčastěji používají ke klasifikaci obrazů a zpracování videozáznamů. Na základě dané aplikace vznikají specializované modely sítí. Architektura CNN je složena z několika stavebních bloků (viz. obrázek 9), mezi základní patří konvoluční vrstva, pooling vrstva a plně propojené vrstvy. První vrstva CNN je vždy tvořena konvoluční vrstvou, na kterou obvykle navazuje pooling vrstva a tato kombinace se několikrát opakuje. Na konec neuronové sítě bývá umístěna alespoň jedna plně propojená vrstva.



Obrázek 9 Schéma konvoluční neuronové sítě [27]

Konvoluční vrstva

Konvoluční vrstva je součástí základní architektury CNN. Jak již vyplývá z názvu vrstvy, provádí se zde operace konvoluce. Konvoluční vrstva zpracovává pomocí malých 2D oken lokální vzory, pokud se jedná o obrazy. Velikost oken je například 3x3. Jednotlivé nalezené vzory si síť zapamatuje, naučí se je. Výhodou je, že naučený vzor síť dokáže rozeznat v jakémkoli místě obrazu a nemusí se ho znovu učit. Další výhodou je, že díky této vlastnosti CNN stačí pro učení méně trénovacích dat. Vlastností CNN je, že se mohou naučit prostorové hierarchie vzorů. Kdy v první vrstvě dojde k naučení malých lokálních vzorů jako jsou hrany. V dalších vrstvách se postupně učí větší vzory. Díky této vlastnosti se CNN může efektivně naučit komplexnější a abstraktnější vizuální pojmy. [22]




Obrázek 10 Ukázka konvoluce [28]

Konvoluce je typ lineární operace, která se používá pro extrakci příznaků. Na vstup je aplikován filtr, malé pole čísel (například 3x3). Konvoluce extrahuje z mapy vstupních příznaků různé oblasti tak, že na ně aplikuje daný filtr. Ten provádí konvoluci, vezme váhy na odpovídajících pozicích a vynásobí je s odpovídajícími hodnotami vstupního obrazu, které se překrývají s daným filtrem. Po provedení konvoluce je na výstupu získána tzv. aktivační mapa. Ta je menší, než vstup, protože jsou používány pouze validní vzorky. Hloubka aktivační mapy bude vždy jedna. Jelikož můžeme mít ve vrstvě více neuronů, můžeme mít i více filtrů. Z aplikace každého filtru získáme jednu aktivační mapu. Na obrázku 10 je ukázka konvoluce. [28]

Aktivační vrstva


Základem aktivační vrstvy jsou aktivační funkce. Používá se v konvoluční vrstvě a snižuje linearitu výstupních hodnot. Mezi nejpoužívanější aktivační funkce v hlubokém učení patří funkce RELU (rectified linear unit). Jedná se o usměrněnou lineární jednotkovou funkci. Je to rychlá funkce, bere jen kladné hodnoty a ty negativní nastavuje na nulu. Její nevýhodou je právě to, že neurčuje chování pro negativní vstupy. Dalšími funkcemi jsou například softmax a sigmoidální funkce. Využívají se ke spojení s finální vrstvou a jejich výstup má podobu pravděpodobnosti určitých dat k vybrané třídě. Použitím aktivační funkce můžeme omezit rozsah výstupu. Například pokud jako poslední vrstvu použijeme aktivační funkci sigmoid, mohla by síť predikovat pouze hodnoty mezi 0 a 1. Na obrázku 11 je zobrazena funkce sigmoid a RELU. [26]



Obrázek 11 Funkce sigmoid a RELU [30]

Pooling vrstva


Sdružovací vrstva provádí podvzorkování, které snižuje velikost vstupních parametrů. Podobně jako u konvoluční vrstvy zde dochází k redukci množství dat kombinováním výstupů z neuronových clusterů v jedné vrstvě do jediného neuronu v další vrstvě. Existuje několik typů poolingů (viz. obrázek 12), například average pooling nebo max pooling. Average pooling vybere z dané oblasti průměrnou hodnotu této oblasti. V případě max poolingů jsou z konvolované části vybírány jen maximální hodnoty. [26]



Obrázek 12 Příklad max poolingů a average poolingů [27]

Plně propojená vrstva


Je to tzv. plně propojená vrstva (viz. obrázek 13), která se většinou řadí na výstup neuronové sítě. Vrstva je pojmenována podle toho, že každý z neuronů této vrstvy je navázán na každý neuron z vrstvy předchozí a zároveň je každý neuron této vrstvy spojen s každým neuronem ve vrstvě další. Úkolem plně propojených vrstev je klasifikovat vstupní obraz do tříd na základě trénovacího datasetu. [26]



Obrázek 13 Příklad plně propojené vrstvy [31]

Dropout vrstva


Jedná se o tzv. vrstvu výpadku, která slouží k regularizaci neuronové sítě. Cílem této vrstvy je zabránit přeučení neuronové sítě. Používá se pouze během procesu učení. Dropout vrstva náhodně vybírá neurony, které budou vypnuty (viz. obrázek 14). Po vypnutí je hodnota výstupu z neuronu rovna nule, v daném kroku učení se tedy nebudou upravovat váhy vypnutých neuronů. Je možné ji aplikovat na jednu nebo všechny vrstvy neuronové sítě. [26]



Obrázek 14 Příklad aplikace dropoutu [32]

3.2.1 1D konvoluční neuronová síť


Hluboké konvoluční neuronové sítě se většinou používají pro zpracování 2D vstupů, jako jsou obrazy nebo videozáznamy, proto bývají označovány jako 2D CNN. Její úpravou vznikla 1D konvoluční neuronová síť (viz. obrázek 15), tzv. 1D CNN. Výhodou takto upravené sítě v porovnání s 2D CNN je výrazně nižší výpočetní náročnost. 1D konvoluční neuronové sítě jsou schopny řešit náročné úlohy pro 1D signály. Tyto problém dokážou řešit i s relativně mělkou architekturou, tzn. s menším počtem skrytých vrstev. Síť s mělkými architekturami je poté mnohem snazší realizovat a natrénovat. Díky nízkým výpočetním nárokům se 1D CNN používají pro analýzy v reálném čase a levné aplikace, především v mobilních telefonech nebo náramkových zařízeních. 1D a 2D konvoluční sítě se od sebe především liší hloubkou sítě, velikostí oken jednotlivých vrstev a pohybem okna, které se u 1D CNN pohybuje pouze podél časové osy. [33]



Obrázek 15 Schéma architektury 1D CNN [33]

3.3 Rekurentní neuronová síť

Rekurentní neuronová síť neboli RNN patří do rodiny neuronových sítí pro zpracování sekvenčních dat. Svoji architekturou je podobná dopředné neuronové síti, liší se tím, jak jsou její neurony vzájemně propojeny. Obsahují smyčky, které umožňují předávání informací. Rekurentní neuronová síť pracuje na principu ukládání informace z výstupu určité vrstvy, kterou přivede zpět na vstup. Tím je umožněno předávání informací z výstupu jednoho kroku na vstup dalšího, a zároveň ovlivňuje nastavení kroku aktuálního. Rekurentní neuronové sítě lze považovat za více kopií stejné sítě, kdy každá předá zprávu následující. Jejich architektura je často řetězová, což umožňuje aplikovat je na úkoly jako je rozpoznávání řeči, jazykový překlad a další. Na obrázku 16 je zobrazeno grafické znázornění RNN. [33]




Obrázek 16 Grafické znázornění RNN [35]

3.3.1 LSTM síť

Long Short Term Memory, tzv. LSTM, tvoří speciální druh rekurentních neuronových sítí. Vznikla za účelem vyřešení problému s mizejícím gradientem. Na rozdíl od rekurentních neuronových sítí si LSTM uchovává v paměti důležité informace a zapomíná ty, které jsou méně důležité. Výhodou je, že dokáže přenášet informaci z daleké historie beze změny. Nevýhodou LSTM je velká výpočetní náročnost. Používají se například k rozpoznávání řeči, analýze textu, na překlady atd.

Všechny rekurentní neuronové sítě mají řetězovou, opakující se strukturu. LSTM obsahuje také opakující se modul, ale má jinou strukturu než u klasické RNN. Na obrázku 17 jsou zobrazeny tři buňky LSTM. Do daných jednotek vstupují jak data nová, tak také stav jednotky předchozího kroku. Architektura LSTM obsahuje speciální jednotky, tzv. paměťové bloky, které se opakují ve skryté vrstvě. Tyto paměťové bloky obsahují buňky s pamětí, které si pamatují (ukládají) dočasný stav sítě. Buňky neobsahují pouze jednu vrstvu, ale čtyři, které na sebe vzájemně působí. [35]



Obrázek 17 Opakující se modul v LSTM [35]

Zapomínající brána

Zapomínající brána rozhoduje, které informace si daná buňka uchová a které by měla ze svého stavu vyhodit. Toto rozhodnutí provádí sigmoidální vrstva, která zpracovává informace z předchozího skrytého stavu a informace z aktuálního vstupu. Rozhodnutí nabývá hodnoty mezi 0 a 1. Hodnoty blíže k 0 říkají, aby došlo k zahazení dané složky vektoru předchozího stavu. Čím blíže je výstupní hodnota 1, tak to znamená zapamatování podoby dané složky vektoru předchozího stavu. [35]

Vstupní brána

Rozhoduje, jaké nové informace budou ukládány ve stavu buňky. Tento proces se dělí na dvě části. Nejprve sigmoidální vrstva rozhodne, které hodnoty budou aktualizovány. Poté se v další vrstvě vytvoří vektor nových hodnot, které bude možné přidat do vnitřního stavu buňky. [35]

Aktualizace vnitřního stavu

Na základě předchozích rozhodnutí dojde k aktualizaci starého stavu buňky na nový stav. Dojde k zapomenutí věcí, o kterých bylo v předchozích krocích rozhodnuto, že budou zapomenuty a jaké nové informace mají být uloženy. [35]

Výstupní brána

Výstupní brána rozhoduje, jaký by měl být další skrytý stav. Pamatuje si informace o předchozích vstupech. Nejprve dojde k předání předchozího skrytého stavu a aktuálního vstupu do funkce sigmoid. Poté je nově upravený stav buňky předán funkci tanh. Následně vynásobíme výstup funkce tanh s výstupem funkce sigmoid, abychom rozhodli, jaké informace by měl obsahovat skrytý stav. Výstupem tedy bude nový skrytý stav, který se přenesou spolu se stavem buňky do dalšího časového kroku. [35][35]

3.4 Přehled používaných klasifikačních metod

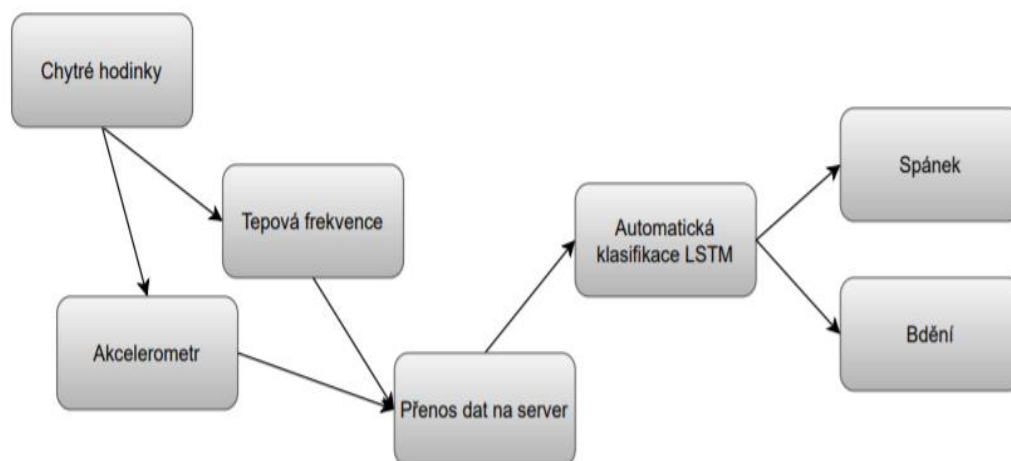
Následující tabulka 1 zobrazuje několik studií provedených v posledních letech. Autoři ve svých studiích využívali moderní zařízení. Pomocí některých z těchto přístrojů byly zaznamenávány biomedicínské signály z lidského těla. Pomocí jiných zařízení byla měřena například akcelerometrická data. K automatické klasifikaci byly využity různé metody, jak jednoduché neuronové sítě, tak hluboké neuronové sítě. Podle výsledků uvedených v tabulce 1 lze konstatovat, že i použití mělkých neuronových sítí vede k vysoké úspěšnosti.

Tabulka 1 Přehled vybraných studií

Autor, rok vydání	G. Jean-Louis et al [10], 2001	Mustafa Radha, et al [11], 2019	R. Casal et al [15], 2020	O. Walch et al. [19], 2019	N. Michielli et al. [40], 2019
Zdroj dat	Akcelerometr (zápěstí)	EKG	Tepová frekvence + SpO ₂	Akcelerometr (zápěstí) +PPG senzor	Jednokanálové EEG
Klasifikované skupiny	W/S	W/ (N1,N2)/ N3/REM	W/S	W/S	N1/REM
Metoda	Adaptivní prahování	LSTM	GRU	Neuronové sítě (MLP)	LSTM
Senzitivita [%]	85	-	94,13	80	N1: 73,56 REM: 87,87
Specifická [%]	54	-	80,26	70,7	N1: 87,87 REM: 73,56
Úspěšnost [%]	-	77	90,13	79,2	N1: 83,56 REM: 83,56

4. NAVRŽENÝ POSTUP KLASIFIKACE

Tato kapitola popisuje postup od počátku měření dat, přes jejich zpracování až k samotnému postupu klasifikace (viz. obrázek 18). Podkapitola 4.1 se zabývá popisem spánkové studie a dat, která jsou použita v této diplomové práci. Data byla naměřena pomocí dvou senzorů umístěných na chytrých hodinkách Apple Watch. Jedná se o záznamy tepové frekvence a akcelerometrická data. V podkapitole 4.2 je podrobný popis procesu předzpracování již zmíněné dvojice dat. Velmi důležitým krokem bylo odstranění úseků, které byly postihnuty technickou chybou nejspíš během ukládání dat na server. K dalším krokům předzpracování patří například doplnění dat pomocí interpolace, vytvoření jednoho vektoru nesoucího informaci o změnách pohybu v jedné ose, která byla vytvořena kombinací původních tří os zrychlení x, y, z nebo vytvoření klasifikačních skupin. V následující podkapitole 4.3 jsou popsány vzorce potřebné pro statistické vyhodnocení jednotlivých modelů. Poslední podkapitola 4.4 obsahuje popis šesti klasifikačních modelů a vyhodnocení jejich úspěšnosti.



Obrázek 18 Schéma navrženého postupu

4.1 Spánková data naměřená Apple Watch

Data ze studie Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device využívaná v této diplomové práci pochází z Michiganské univerzity. Sběr dat probíhal od června roku 2017 do března roku 2019. Studie se zúčastnilo celkem 39 dobrovolníků. Kompletních záznamů bylo získáno od 31 osob. V tabulce 2 jsou shrnuty základní údaje o datech ze studie. [19]

Protokol měření

Od všech zúčastněných byl požadován písemný informovaný souhlas. Spolu se souhlasem museli účastníci vyplnit dotazník, který měl vyloučit přítomnost známých diagnóz nežádoucích při provádění studie. Příkladem některých z diagnóz je syndrom neklidných nohou, kardiovaskulární onemocnění (vrozené srdeční vady, infarkt myokardu, ischemická choroba srdeční, arytmie atd.), periferní cévní onemocnění, poruchy dýchání související se spánkem, nespavost, parasomnie, hypersomnie, poruchy zraku (u kterých nelze provést brýlovou korekci) nebo jiné poruchy, které mají významný vliv na neurologické poškození. Ze studie byly vyloučeny osoby, které se během posledního měsíce zúčastnily práce na noční směně nebo ty, které podnikly let přes více jak dvě časová pásma. Pomocí Epworthské škály spavosti (Epworth Sleepiness Scale) byli nalezeni účastníci, kteří trpí nadměrnou denní spavostí. Jedinci, kteří v dotazníku získali skóre větší než 10 byli ze studie vyloučeni.

Účastníci, kteří byli vybráni do studie následně obdrželi chytré hodinky Apple Watch (Series 2 and 3, Apple Inc). Tato zařízení nosili v průběhu 7 – 14 dnů. Výjimkou byl čas potřebný pro nabití hodinek. Poslední noc studie strávili dobrovolníci ve spánkové laboratoři, kde podstoupili polysomnografické vyšetření. I během PSG vyšetření měli účastníci na sobě Apple Watch. Data z hodinek byla přenášena do mobilního telefonu, odkud probíhalo nahrávání dat na server.

Poslední noc studie podstoupili účastníci osmihodinové PSG vyšetření, které probíhalo podle uznávaného standardizovaného hodnocení AASM. Výjimku tvořilo měření pomocí oronasálního termistoru a senzoru nosního tlaku. Vyšetření proběhlo za použití měření pomocí EEG, EOG, bradového EMG, 2 – svodové EKG, hrudního a abdominálního pletysmografu (RIP), mikrofonu k určení chrápání a pulzního oxymetru.

Elektrofyzilogické signály prvních osmi účastníků byly naměřeny pomocí přístroje Vitaport3 (TEMEC Instruments B.V.). Všechny ostatní signály byly získány pomocí diagnostického zařízení Graef HD – PSG/EEG (Compumedics, USA Inc.). Data byla naměřena s vzorkovací frekvencí 256 Hz a uložena pro vizuální hodnocení, které probíhalo podle skórovacího manuálu AASM. Jako alternativa byly k určení apnoe a hypopnoe použity pletysmografy.

Zároveň s PSG vyšetřením pokračovalo měření pomocí Apple Watch. S tím rozdílem, že u hodinek byly pozměněny parametry měření. Nastavením jiného programu došlo

ke snížení vzorkovací frekvence, tudíž zaznamenávání tepu probíhalo každých 5 sekund. [19]


Tabulka 2 Shrnutí údajů o datech

Sběr dat	2017 – 2019
Měřicí zařízení	Apple Watch
Délka měření	7 – 14 dní
Měřicí senzory	MEMS akcelerometr a optický PPG senzor
Počet záznamů	31
Účastníci	Bez nežádoucích diagnóz (např. kardiovaskulární onemocnění, poruchy dýchání, nespavost atd.)
Akcelerometrická data	50 Hz / 20 Hz
Tepová frekvence	Neekvidistantní vzorkování závislé na intenzitě pohybu
PSG vyšetření	Poslední noc studie
PSG vyšetření	EEG, EOG, EMG brady, EKG, hrudní a abdominální pletysmograf, pulzní oxymetr, mikrofon (chrápání)
Hodnocení PSG	Podle AASM

Popis naměřených dat


Naměřená data byla získána pomocí chytrých hodinek Apple Watch (Series 2 and 3, Apple Inc). Na hodinkách jsou umístěny dva senzory, tříosý MEMS akcelerometr a optický PPG senzor. Akcelerometr se využívá pro zaznamenání zrychlení, tudíž dává informace o pohybu. PPG senzor byl použitý pro měření tepové frekvence.

Data o zrychlení, získaná pomocí MEMS senzoru, jsou tvořena třemi vektory. Na obrázku 19 je ukázka dat získaných z akcelerometru. Tyto vektory reprezentují zrychlení v osách x, y a z. Zrychlení bylo zaznamenáno v rozmezí $\pm 16 \text{ g}$ ($\text{m}\cdot\text{s}^{-2}$). Čtvrtý vektor, který se zde objevuje, je časová osa v sekundách, která je datována od 1. ledna 1970. Časová osa udává čas v sekundách před začátkem PSG a po začátku vyšetření. Čas před začátkem PSG je dán zápornými sekundami. Akcelerometrická data byla vzorkována se vzorkovací frekvencí 50 Hz. Výjimku tvořili dva účastníci, u nichž byla data vzorkována s frekvencí 20 Hz, kvůli obavě o životnost baterie.



Obrázek 19 Ukázka akcelerometrických dat

Pomocí optického PPG senzoru s infračervenými diodami byla měřena tepová frekvence. Tep byl měřen v rytmech za minutu (bpm) po několika sekundách. Vzorkovací frekvence, stejně jako v předchozím případě, je závislá na pohybu uživatele. Proto byl tento signál interpolován, aby byla výsledkem hodnota pro každou vteřinu záznamu. Na obrázku 20 je ukázka dat naměřených pomocí PPG senzoru. Na ose x je čas v hodinách po začátku PSG vyšetření. [19]




Obrázek 20 Ukázka dat naměřených pomocí PPG senzoru

4.2 Předzpracování dat

Před samotnou klasifikací bylo nutné data nejprve správně předzpracovat. Z načtených dat byly vybrány části záznamů, které byly zaznamenávány společně s polysomnografií. Čas před začátkem PSG vyšetření je reprezentován zápornými sekundami a od začátku vyšetření byla časová osa zaznamenávána v kladných sekundách. Data tepové frekvence i akcelerometrická data odpovídající kladnému času byly následně rozděleny do epoch, jejichž délka odpovídá 30 sekundám.


Následně bylo nutné odstranit ty epochy, u kterých nejspíš došlo k technické chybě během měření nebo ukládání dat na server. Z dat tepové frekvence byly odstraněny epochy, které obsahovaly méně než pět hodnot. Převážně se zde vyskytovaly epochy, během kterých byla zaznamenána pouze jedna hodnota. Stejně tak byla upravena akcelerometrická data, u kterých byly odstraněny epochy, které obsahovaly pouze jednu hodnotu. Dále byly odstraněny ještě ty epochy, které obsahovaly méně než 800 hodnot, protože se jednalo o malé množství hodnot nevhodné pro následující úpravy. V rámci výše zmíněných úprav bylo upraveno i PSG hodnocení. Nevyhovující epochy byly označeny číslem -5. Na obrázku 21 je ukázka upraveného hypnogramu. Označení *Nehodnoceno 1* neodpovídá žádné z fází N, REM nebo bdění. Navíc hypnogram obsahuje popis *Nehodnoceno 2*, který reprezentuje vyřazené epochy.



Obrázek 21 Ukázka upraveného hypnogramu


Kvůli výskytu nedostatečné informace v datech tepové frekvence musela být data upravena. Tento problém byl vyřešen lineární interpolací pro každou sekundu záznamu. Výsledkem jsou 30 sekund dlouhé epochy, kdy každé vteřině odpovídá jedna hodnota tepové frekvence.

Akcelerometrická data měla být zaznamenána se vzorkovací frekvencí 50 Hz, tudíž by 30 - sekundová epocha měla obsahovat 1500 hodnot. Jelikož během přenosu nejspíš docházelo k problémům s ukládáním dat, nebyl tento předpoklad naplněn. Tudíž se v datech vykytovalo několik možností odklonu dat od požadovaného počtu hodnot. V prvním případě epochy obsahovaly výrazně méně hodnot než předpokládaných 1500. Pokud chybějící hodnoty nebyly zaznamenány během celé 30 - sekundové epochy, ale bylo zde patrné přerušení zaznamenání dat, byly tyto epochy doplněny augmentací, přesněji duplikací jejích vlastních hodnot. Druhou možností bylo doplnění chybějících hodnot interpolací. Zde nedošlo k přerušení během měření hodnot a chybění například 10 sekund záznamu, ale jednalo se o chybu způsobenou nepravidelným vzorkováním. Na obrázku 22 je příklad augmentací doplněné epochy.



Obrázek 22 Ukázka epochy s chybějícími hodnotami

V dalším případě epochy obsahovaly více hodnot. Interval zaznamenávání byl odlišný než 0,02 sekundy, tudíž nebyla dodržena vzorkovací frekvence 50 Hz. Proto bylo nutné epochy vhodně upravit na požadovanou velikost 1500 hodnot ve 30 - sekundovém záznamu. Úprava byla provedena podvzorkováním. Ve třetím případě došlo k použití jiné vzorkovací frekvence. Hodnoty byly rovnoměrně zaznamenávány během celého trvání epochy, ale jejich celkový počet byl pouze kolem 300 hodnot. Proto byly doplněny pomocí lineární interpolace na požadovaný počet 1500 hodnot, viz. obrázek 23.




Obrázek 23 Ukázka interpolace epochy s původním počtem 300 hodnot

Následně byla předzpracována akcelerometrická data, která byla zaznamenána ve třech osách x, y a z. Z těchto tří vektorů byl přepočten vytvořen jeden vektor, který nese informaci o změnách pohybu v jakékoli ose. Přepočet byl proveden po jednotlivých epochách pomocí parametru Signal Vector Magnitude, zkráceně označován jako SVM. [37]

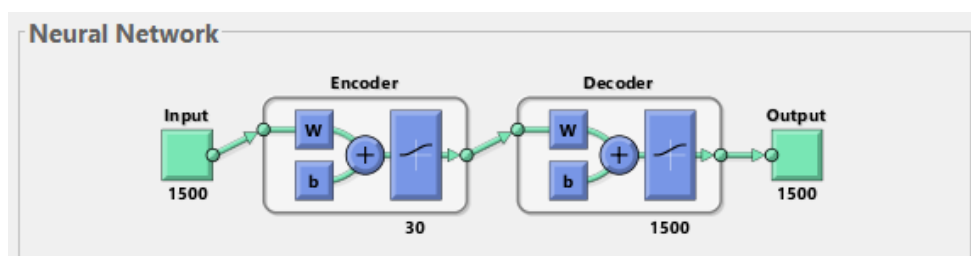
$$SVM(k) = \sqrt{x_i^2(k) + y_i^2(k) + z_i^2(k)}, \quad (4.1)$$

Na obrázku 24 jsou zobrazeny vektory zrychlení v osách x, y a z, společně s vektorem SVM vypočítaným z těchto tří vektorů.



Obrázek 24 Ukázka upravených dat z akcelerometru


Data z akcelerometru bylo ještě potřeba upravit tak, aby jejich délka korespondovala s délkou epochy tepové frekvence. Tudiž bylo třeba získat 30 hodnot pro každou jednu epochu. Toho bylo dosaženo odvozením příznaků v požadovaném počtu za vzniku vektoru dané délky. K odvození příznaků byl použitý autoenkodér, což je označení pro typ dvouvrstvé neuronové sítě. Skládá se ze dvou dílčích částí, enkodéru, který provádí komprimaci vstupních dat a dekodéru, který zkomprimovaná data dekomprimuje. Počet vstupů sítě odpovídá počtu jejich výstupů. Cílem této sítě je pomocí enkodéru zakódovat data a pomocí dekodéru je poté dekodovat. Mezi enkodérem a dekodérem je tzv. bottleneck. Obsahuje méně neuronů, než je velikost vstupu, resp. počtu neuronů výstupní vrstvy. Bottleneck určuje, jak moc budou data komprimována. Velikost bottlenecku byla volena podle požadavku na výslednou velikost epochy. Na obrázku 25 je ukázka použitého autoenkodéru.




Obrázek 25 Ukázka autoenkodéru pro extrakci vektoru délky 30

Aby bylo možné data klasifikovat do požadovaných skupin na bdělost/spánek a bdělost/NREM/REM, musí k tomu být vhodně upravena. Během vytváření obou klasifikačních skupin nebylo třeba upravovat epochy reprezentující bdělost. K vytvoření požadované spánkové skupiny bylo potřeba sloučit epochy hodnocené jako N1, N2, N3 a REM. Dále byla vytvořena klasifikační skupina NREM sloučením epoch N1, N2 a N3 dohromady. Skupinu REM v případě klasifikování do tří tříd bdělost/NREM/REM zůstala bez úprav. Skórovaná data obsahovala kromě ohodnocených fází také neohodnocené epochy, které byly odstraněny.

Následně byla data rozdělena na trénovací a testovací množinu v poměru 80:20. Pro testování sítě bylo použito šest úplných záznamů. U neúplných záznamů došlo k přerušení zaznamenávání dat během PSG vyšetření. Na obrázku 26 je zobrazen nejkratší záznam, během kterého byla data měřena pouze jednu hodinu, pak došlo k vybití baterie u hodinek. Na následujícím obrázku 27 je vykreslen hypnogram z PSG vyšetření, které oproti měření dat z hodinek probíhalo po celou noc. Proto tyto záznamy nejsou vhodné pro testování sítě, ale byly použity pro její trénování. Trénovací data byla dále rozdělena na trénovací a validační množinu, která se používá jako ochrana před možným přeučením neuronové sítě.



Obrázek 26 Ukázka neúplných dat




Obrázek 27 Ukázka kompletního hypnogramu neúplného záznamu tepové frekvence a akcelerometru (viz. obrázek 26)

Dalším důležitým krokem k dosažení správné detekce spánku je standardizace naměřených hodnot. Provedením standardizace proměnných dojde k jejich převedení na stejné měřítko. Ke standardizaci parametrů byla použita standardizace směrodatnou odchylkou neboli výpočtem tzv. z-skóre (4.2). Po standardizaci získáme odvozená data, jejichž aritmetický průměr je roven nule a směrodatná odchylka je rovna jedné.

$$z = \frac{x_i - \mu}{\sigma}, \quad (4.2)$$

kde μ je střední hodnota (průměr) a σ je směrodatná odchylka. Na obrázku 20 je ukázka dat tepové frekvence, které byly lineárně interpolovány a následně standardizovány.

Naproti tomu obrázek 28 zobrazuje stejný záznam tepové frekvence, před těmito úpravami.



Obrázek 28 Ukázka dat tepové frekvence po standardizaci

Aby bylo dosaženo kvalitních výsledků LSTM sítě, je vhodné mít pro trénování sítě stejné množství dat ve všech klasifikovaných kategoriích. V tomto případě se jedná o přibližně stejné množství dat pro fáze bdělosti a pro spánek. Srovnání délek obou skupin bylo provedeno zmnožením hodnot ve fázi bdělosti a doplněním, aby počet fází bdělosti a fází spánku byl přibližně stejný.

4.3 Statistické vyhodnocení výsledků

Po otestování modelu je důležité zjistit, v kolika případech došlo ke správnému určení dané epochy a kdy bylo zařazení chybné. Údaje o statistickém zhodnocení modelu zachycuje matice záměn. Matice přehledně zobrazuje úspěšnost daného modelu. Na obrázku 29 je příklad matice záměn pro klasifikaci do dvou kategorií bdělost (Wake) a spánek (Sleep).

Predikovaná kategorie	Skutečná kategorie			
		Bdění	Spánek	
	Bdění	TN	FN	NPV
	Spánek	FP	TP	PPV
		Specificita	Senzitivita	Celková úspěšnost

Obrázek 29 Matice záměn pro klasifikaci do dvou kategorií [38]

TN (skutečně negativní) označuje, kolik fází bdělosti (W) bylo správně klasifikováno jako bdělost. TP (skutečně pozitivní) označuje, kolik fází spánku (S) bylo správně klasifikováno jako spánek. FN (falešně negativní) označuje, kolik epoch bylo chybně predikováno jako bdělost, ačkoli se jednalo o spánek. FP (falešně pozitivní) označuje, kolik fází bdělosti bylo chybně predikováno jako spánek.

Z údajů uvedených v matici záměn lze vypočítat statistické parametry, které se používají k vyhodnocení kvality predikce modelu. Mezi tyto parametry řadíme např. senzitivitu, specificitu, F_1 skóre a celkovou úspěšnost. Popis těchto parametrů se vzorci je uveden níže. [38]

Senzitivita (citlivost) udává úspěšnost určení spánkové kategorie:

$$Senzitivita = \frac{TP}{TP + FN} \quad (4.3)$$

Specificita udává podíl skutečně negativních výsledků testu (tj. Wake) ke všem negativním výsledkům.

$$Specificita = \frac{TN}{TN + FP} \quad (4.4)$$

Pozitivní prediktivní hodnota (PPV) udává počet skutečně pozitivních výsledků dělených počtem všech pozitivních výsledků.

$$PPV = \frac{TP}{TP + FP} \quad (4.5)$$

F_1 skóre měří celkovou úspěšnost testu. Závisí na senzitivě a pozitivní prediktivní hodnotě. Oproti celkové úspěšnosti (accuracy) bere v potaz počty vzorků v jednotlivých hodnocených skupinách.

$$F_1 = 2 \cdot \frac{PPV \cdot Senzitivita}{PPV + Senzitivita} \quad (4.6)$$

Celková úspěšnost (accuracy) je relativní počet správných rozhodnutí klasifikátoru.

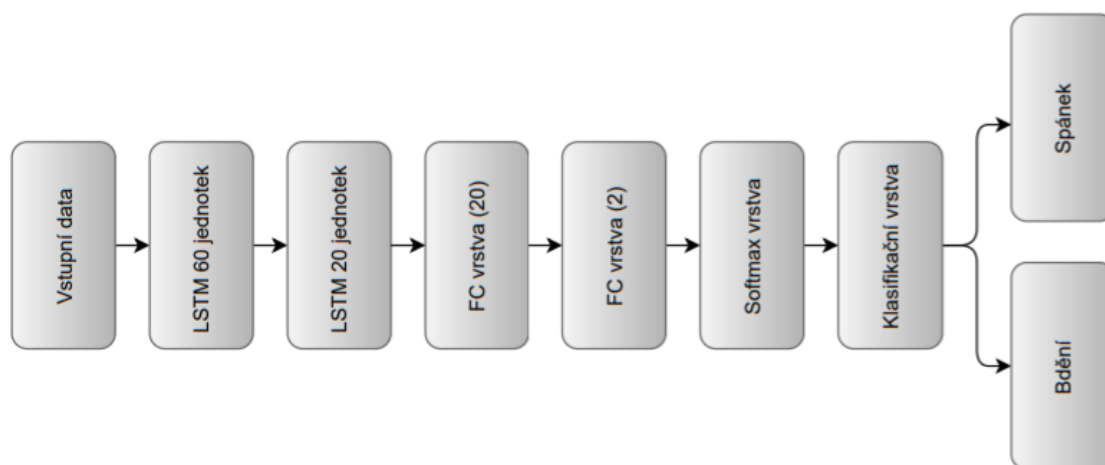
$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (4.7)$$

4.4 Klasifikace spánkových stádií

V rámci zpracování této diplomové práce bylo vytvořeno několik klasifikačních modelů. První model provádí klasifikaci na spánek a bdění. Druhý model je složitější, jelikož klasifikuje data do tří skupin na bdění, NREM a REM spánek. Ke klasifikaci byla vybrána technika založená na hlubokém učení. LSTM síť byla vytvořena v programovém prostředí MATLAB2020. Tato síť byla vybrána kvůli své schopnosti naučit se dlouhodobé závislosti v signálech.

4.4.1 Klasifikace spánek vs. bdění s využitím tepové frekvence

Klasifikační síť je realizována rekurentní neuronovou sítí, konkrétně LSTM sítí. Je to síť hlubokého učení a je založena na metodě učení s učitelem, kdy na vstup je přivedena matice vstupních příznaků a matice požadovaných výstupů, které jsou předem známe. V tomto případě jeden řádek vstupní matice reprezentoval jednu epochu o délce 30 sekund, kdy každá sekunda byla zastoupena jednou hodnotou tepové frekvence. Matice požadovaných výstupů měla podobu vektoru, ve kterém byly uloženy kategoriální proměnné, které určovaly, zda daná epocha patří do kategorie spánku nebo bdění. Klasifikační síť modelu 1 je složena z následujících částí a schéma celé její architektury je znázorněno na obrázku 30. Síť je tvořena dvěma vrstvami, počet jednotek první vrstvy je 60 a druhá vrstva má 20 jednotek. Následují dvě plně propojené vrstvy. Výstup první plně propojené vrstvy je vektor 20 příznaků. Výstup druhé vrstvy má délku 2, a to z důvodu klasifikace do dvou tříd.



Obrázek 30 Grafické znázornění použité architektury LSTM modelu 1

Ke trénování sítě bylo využito 25 záznamů, které byly následně ještě rozděleny na trénovací a validační množinu v počtu 18:7. Jelikož záznamy obsahovaly více fází spánku než bdění, byly obě množiny doplněny chybějícími fázemi na přibližně stejný počet. Celkový počet fází spánku byl 9919 a počet fází bdění byl 9251. Model 1 byl následně na takto připraveném datasetu trénován po dobu 10 epoch. Při trénování na větším počtu

epoch již nedocházelo ke vývoji křivky přesnosti ani k učení. Pro učení sítě byl zvolen optimizer Adam. Velikost batche byla nastaven na hodnotu 45. Při zvolení větší hodnoty docházelo ke klasifikování převážně fází bdění, naopak při výběru menšího čísla byly téměř všechny fáze klasifikovány jako spánek. Následující tabulka 3 obsahuje hodnoty matice záměn získané na trénovacích datech. Klasifikační síť rozpoznává lépe spánek. Zároveň z hodnot v matici vyplývá, že velký počet epoch bdění byl označen jako spánek.

Tabulka 3 Matice záměn trénovacích dat – model 1

<i>Matice záměn</i>		<i>Predikovaná kategorie</i>	
		<i>Spánek</i>	<i>Bdění</i>
<i>Skutečná kategorie</i>	<i>Spánek</i>	7093	2826
	<i>Bdění</i>	6305	2946

Testování na natrénované síti bylo provedeno na 4071 datech. Výsledky klasifikace jsou uvedeny v tabulce 4. Z výsledků je patrné, že síť se naučila rozeznávat převážně spánek. Fázi bdění se síti podařilo správně klasifikovat pouze ve 124 případech z celkového počtu 305 epoch. Vysoký počet chybných klasifikací byl nejspíš způsoben tím, že určité fáze spánku jsou velmi podobné bdění.

Tabulka 4 Matice záměn testovacích dat – model 1


<i>Matice záměn</i>		<i>Predikovaná kategorie</i>	
		<i>Spánek</i>	<i>Bdění</i>
<i>Skutečná kategorie</i>	<i>Spánek</i>	2416	1350
	<i>Bdění</i>	181	124


V tabulce 5 je zobrazeno statistické vyhodnocení modelu. Tabulka je doplněná o údaje po odstranění jednoho a dvou záznamů, u kterých došlo k detekování převážně jen bdění. Výsledky statistického vyhodnocení po postupném smazání těchto záznamů ukazují, že došlo ke zvýšení hodnot senzitivity, úspěšnosti a F1 skóre. Naproti tomu u specificity došlo k poklesu o 10 %. Statistické výsledky pouze na čtyřech záznamech vykazují nejvyšší hodnotu F1 skóre, které byla 89,29 %.

Tabulka 5 Statistické vyhodnocení modelu 1


	6 záznamů		5 záznamů	4 záznamy
	Trénovací data	Testovací data	Testovací data	Testovací data
Senzitivita	71,51 %	64,15 %	76,78 %	85,11 %
Specifická	31,87 %	40,66 %	34,78 %	30,35 %
Celková úspěšnost	52,38 %	62,39 %	73,34 %	81,09 %
F1 skóre	60,84 %	75,94 %	84,09 %	89,29 %

Obrázek 31 zobrazuje výsledek klasifikace pro testovací data na čtyřech záznamech. V tabulce 5 je možné pozorovat, že po odstranění dvou záznamů z testovacích dat, došlo ke zvýšení F1 skóre z hodnoty 75,94 % na 89,09 %. Na obrázku 32 je vykreslen nejhorší výsledek klasifikace, kdy byla většina epoch označena jako bdění. Nejspíš to bylo způsobeno vyšší hodnotou tepové frekvence v daném záznamu v porovnání s ostatními záznamy. Na obrázku 33 je výsledek jednoho z nejlépe klasifikovaných záznamů. V příloze A.1 jsou uvedeny ukázky dalších výsledků klasifikace pro jednotlivé záznamy i pro všech šest záznamů dohromady.

**Obrázek 31** Výsledek klasifikace pro testovací data modelu 1 na čtyřech záznamech



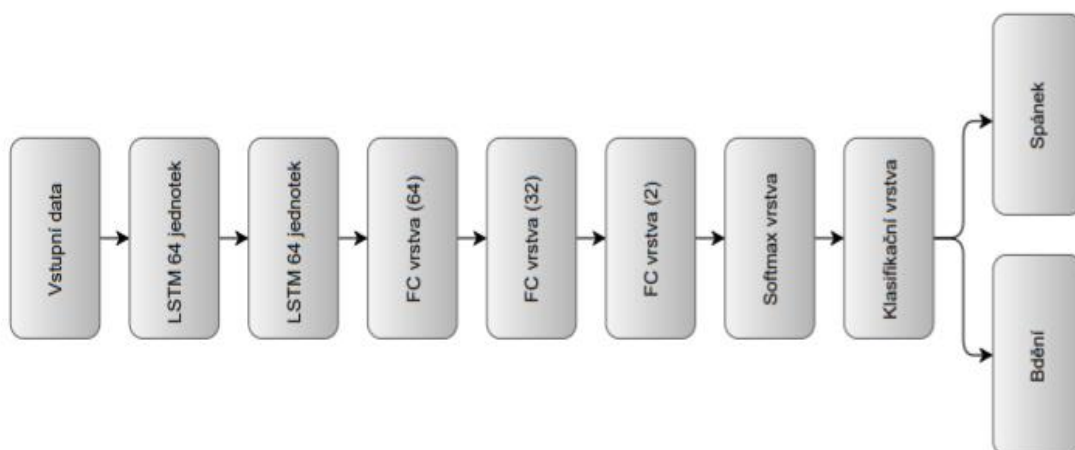
Obrázek 32 Výsledek klasifikace pro testovací data modelu 1 pro 1 záznam



Obrázek 33 Výsledek klasifikace pro testovací data modelu 1 pro 1 záznam

4.4.2 Klasifikace spánku vs. bdění s využitím akcelerometru

Následující podkapitola obsahuje popis modelu 2, který provádí klasifikaci na spánek a bdění s využitím pouze akcelerometrických dat. Použitá data neprošla všemi kroky zpracování, jako je uvedeno v kapitole 4.2. Rozdílem bylo vynechání kroku přípravy pomocí neuronové sítě autoenkodéru. Data, která prošla procesem zpracování autoenkodérem mají délku 30 hodnot na jednu epochu. Vstupem LSTM sítě jsou tedy jednotlivé epochy, kdy jedna obsahuje 1500 pohybových hodnot. Matice požadovaných výstupů měla podobu vektoru, ve kterém byly uloženy kategoriální proměnné, které určovaly, zda daná epocha patří do kategorie spánku nebo bdění. Na obrázku 34 je grafické znázornění použité architektury modelu 2. Síť je tvořena dvěma vrstvami, které jsou složeny ze 64 jednotek. Následují tři plně propojené vrstvy, výstupem první z nich je vektor hodnot o délce 64 příznaků. Výstup druhé plně propojené vrstvy má délku 32 příznaků. Poslední vrstva má délku 2, a to z důvodu klasifikace do dvou skupin na spánek a bdění.



Obrázek 34 Grafické znázornění použité architektury LSTM modelu 2

Ke trénování sítě bylo využito stejně jako u předchozího modelu 25 záznamů. Jelikož záznamy obsahovaly více fází spánku než bdění, byly doplněny chybějícími fázemi bdění, aby byl jejich počet přibližně stejný. Model 2 byl trénován po dobu 10 epoch. Při trénování na větším počtu epoch již nedocházelo ke vývoji křivky přesnosti ani k učení. Pro učení sítě byl zvolen optimizér Adam. Velikost batche byla nastavena na hodnotu 102. Obrázek 35 zobrazuje grafy popisující průběh učení modelu. Horní graf popisuje hodnotu přesnosti (accuracy) a dolní hodnotu chyby (loss) v závislosti na počtu epoch. V grafu popisujícím celkovou hodnotu přesnosti byla nejvyšší dosažená hodnota přesnosti 65 %. Z průběhu popisujícího chybu lze konstatovat, že téměř nedocházelo k učení modelu.



Obrázek 35 Průběh učení modelu 2

Natrénovaná síť na 4071 datech dosahovala srovnatelných výsledků s předchozím modelem 1. Výsledky klasifikace modelu 2 jsou uvedeny v tabulce 6. Síť se naučila lépe rozeznávat spánek než fáze bdění. Rozpoznání bdění se síti podařilo správně určit ve více než polovině, tzn. ve 174 případech z celkového počtu 305 epoch. Správné určení spánku se síti podařilo také ve více než 50 % testovaných fázích.

Tabulka 6 Matice záměn testovacích dat – model 2

Matice záměn		Predikovaná kategorie	
		Spánek	Bdění
Skutečná kategorie	Spánek	2676	1090
	Bdění	131	174

V tabulce 7 je zobrazeno statistické vyhodnocení modelu 2. Trénovací data dosáhla senzitivity 86,46 %, tato hodnota byla vyšší oproti testovacím datům. Hodnota F1 skóre, které měří celkovou úspěšnost testu byla 81,42 %. V porovnání s modelem 1 bylo u modelu 2 na 6 testovacích záznamech dosaženo vyšší specificity během testování,

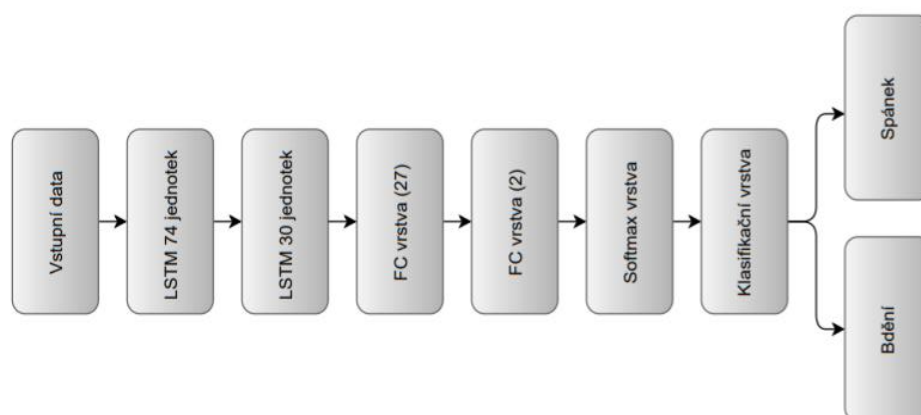
rozdíl tvořil 16,39 %. U modelu 2 byly hodnoty statistického vyhodnocení vyšší na trénovacích i testovacích datech.

Tabulka 7 Statistické vyhodnocení modelu 2

	Trénovací data	Testovací data
Senzitivita	86,46 %	71,06 %
Specifická	41,28 %	57,05 %
Celková úspěšnost	64,65 %	70,01 %
F1 skóre	71,68 %	81,42 %


4.4.3 Klasifikace spánku vs. bdění s využitím tepové frekvence a akcelerometru

Další model využívá ke klasifikaci spánku a bdění předzpracované záznamy tepové frekvence i akcelerometrických dat. Do sítě vstupují epochy, které jsou zastoupeny dvěma řádky, v prvním jsou zaneseny hodnoty tepové frekvence o stejné délce jako je délka epochy, tudíž 30. Ve druhém řádku jsou zaznamenány akcelerometrická data také o stejné délce 30. Klasifikační síť modelu 3 je zobrazena na obrázku 36 a je složena z následujících částí. Tvoří ji dvě vrstvy, počet jednotek první vrstvy je 74 a druhé 30. Následují dvě plně propojené vrstvy. Výstup první plně propojené vrstvy je vektor 27 příznaků. Výstup druhé vrstvy má délku 2, a to z důvodu klasifikace do dvou tříd na bdění a spánek. Síť byla trénována na 25 záznamech, které byly rozděleny na trénovací a validační množinu. Trénování modelu 3 probíhalo po dobu 10 epoch. Příloha A.2 obsahuje graf zobrazující průběh učení. Pro učení sítě byl zvolen optimizátor Adam. Velikost batche byla nastavena na hodnotu 55.




Obrázek 36 Grafické znázornění použité architektury LSTM modelu 3

Na obrázku 37 jsou zobrazeny vybrané průběhy normalizovaných akcelerometrických dat. Legenda popisuje skutečnou/predikovanou fázi spánku, symbol *w* označuje bdění a *s* spánek. Průběhy jsou vykresleny ze dvou záznamů a z různých úseků během celé noci, například uprostřed noci, před probuzením atd. Graf jasně ukazuje, že velké množství průběhů spánku a bdění jsou totožné. Na základě těchto shodných průběhů lze označit tyto akcelerometrická data, po zpracování pomocí autoenkodéru, za nevhodná pro klasifikaci, jelikož neobsahují dostatečnou informaci k rozlišení bdění a spánku.



Obrázek 37 Graf zobrazující průběhy normalizovaných akcelerometrických dat (skutečné/predikované fáze, *w* – bdělost, *s* – spánek)

Na obrázku 38 je graf, ve kterém jsou vykresleny normalizované průběhy tepové frekvence. Každý průběh odpovídá jedné epoše, tzn. jeho délka je 30 sekund. Legenda popisuje skutečnou/predikovanou fázi spánku, symbol *w* označuje bdění a *s* spánek. Jednotlivé průběhy zobrazené na obrázku 37 pochází ze stejných epoch jako ty na obrázku 38. Pro větší přehlednost nebyly všechny průběhy zaneseny do jednoho grafu. Jak bylo zmíněno výše, zobrazené průběhy pochází ze dvou patientských záznamů. Hodnoty dané fáze jsou odlišné u zobrazených záznamů, ale také v rámci záznamu jednoho pacienta nabývají průběhy různých hodnot. Ve srovnání s předchozím grafem zobrazujícím akcelerometrická data jsou záznamy tepové frekvence rozdílnější. Tyto průběhy jsou vzájemně odlišnější oproti zobrazeným akcelerometrickým datům, avšak správná klasifikace je stále velmi obtížná.



Obrázek 38 Graf zobrazující průběhy normalizované tepové frekvence (skutečné/predikované fáze, w – bdělost, s – spánek)


Následující dvě tabulky zobrazují matice záměn pro testovací data. První tabulka 8 zobrazuje výsledky pro všechny záznamy a druhá tabulka 9 obsahuje výsledky pouze pro 5 záznamů. Z porovnání tabulek je patrné, že v odstraněném záznamu byla většina epoch chybně klasifikována jako bdění, ačkoli se jednalo o spánek. Celkový počet spánkových fází v odstraněném záznamu, které byly chybně označeny jako bdění, byl 543 a počet epoch bdění, které byly správně detekovány jako bdění, byl 28. Po odstranění záznamu došlo k poklesu taktéž počtu správně klasifikovaných spánků. Rozdíl činil 131 epoch. Porovnání statistického vyhodnocení modelu s kompletním a menším počtem testovaných záznamů je uveden v tabulce 10. Obrázek 39 zobrazuje výsledek klasifikace pro testovací data na 5 záznamech. Pro porovnání je v příloze A.2 uveden výsledek klasifikace na všech záznamech.

Tabulka 8 Matice záměn testovacích dat 6 záznamů – model 3

Matice záměn		Predikovaná kategorie	
		Spánek	Bdění
Skutečná kategorie	Spánek	2713	1053
	Bdění	196	109

Tabulka 9 Matice záměn testovacích dat 5 záznamů – model 3

Matice záměn		Predikovaná kategorie	
		Spánek	Bdění
Skutečná kategorie	Spánek	2582	510
	Bdění	195	81



Obrázek 39 Výsledek klasifikace pro testovací data modelu 3 pro 5 záznamů


Tabulka 10 zobrazuje statistické vyhodnocení modelu 3. Tabulka je doplněná o údaje po odstranění jedno záznamu, u kterého byla detekována většina epoch chybně jako bdění, ačkoli se jednalo o spánek. Výsledky statistického vyhodnocení po smazání daného záznamu ukazují, že došlo ke zvýšení hodnot senzitivity, úspěšnosti a F1 skóre, v průměru o 9 %. Nejvyšší nárůst byl u senzitivity, u kterého došlo ke zvýšení z 72,04 % na 83,15 %. Naproti tomu u specifity došlo k poklesu hodnoty, zhruba o 6 %.

Tabulka 10 Statistické vyhodnocení modelu 3

		6 záznamů	5 záznamů
	Trénovací data	Testovací data	Testovací data
Senzitivita	73,77 %	72,04 %	83,51 %
Specifita	28,88 %	35,74 %	29,35 %
Celková úspěšnost	52,10 %	69,32 %	79,07 %
F1 skóre	61,44 %	81,29 %	87,99 %

4.4.4 Klasifikace na bdění vs. NREM vs. REM s využitím tepové frekvence

Model 4 provádí klasifikaci pomocí LSTM sítě s využitím jednoho parametru, a to tepové frekvence. Do sítě vstupují epochy o délce 30 sekund a každá epocha obsahuje 30 hodnot tepové frekvence. Na výše zmíněný počet hodnot bylo třeba data vhodně upravit pomocí lineární interpolace, protože původní data nebyla zaznamenána pravidelně. Všechny další potřebné kroky předzpracování jsou uvedeny v kapitole 4.2 popisující předzpracování dat. Celá architektura použité sítě je znázorněna na obrázku 40. Síť je tvořena dvěma LSTM vrstvami. Obě vrstvy jsou složeny ze stejného počtu podjednotek, a to ze 64. Následují dvě plně propojené vrstvy, tzv. fully connected (FC) vrstvy. První plně propojená vrstva má velikost 45, což znamená, že jejím výstupem je vektor o délce 45 příznaků. Na ni navazuje druhá plně propojená vrstva, která má délku 3, a to z důvodu klasifikace na fáze bdění, NREM a REM. Trénování sítě proběhlo na 25 záznamech. Samotné trénování probíhalo po dobu 10 epoch. Pro učení sítě byl zvolen optimizér Adam a velikost batche byla nastavena na hodnotu 104.



Obrázek 40 Grafické znázornění použité architektury LSTM modelu 4

Tabulka 11 obsahuje výsledky klasifikace na trénovacích datech modelu 4. Nejlepší výsledky byly dosaženy pro správné určení NREM fáze. Z celkového počtu 7455 případů bylo správně klasifikováno 4798 epoch. Počet skutečných NREM, které byly klasifikovány jako REM byl 2067 a jako bdění 590. REM byl správně určen ve 2298 případech. Fázi bdění se síti podařilo správně klasifikovat ve 773 případech z celkového počtu 6648 epoch.


Tabulka 11 Matice záměn trénovacích dat – model 4

<i>Matice záměn</i>		<i>Predikovaná kategorie</i>		
		<i>NREM</i>	<i>REM</i>	<i>Bdění</i>
<i>Skutečná kategorie</i>	<i>NREM</i>	4798	2067	590
	<i>REM</i>	2825	2298	703
	<i>Bdění</i>	3856	2019	773

Síť byla otestována na 4071 datech. Výsledky klasifikace jsou uvedeny v tabulce 12. Jako v předchozím případě se síť nejlépe naučila rozpoznávat NREM fázi. Správně určených fází NREM bylo 2079. Počet skutečných NREM, které byly klasifikovány jako REM byl 579 a jako bdění pouze 299. REM byl správně určen ve 224 případech z celkového počtu z 809. Fázi bdění se síti podařilo správně klasifikovat pouze ve 41 případech z celkového počtu 305 epoch. Na obrázku 41 je zobrazen výsledek klasifikace pro testovací data modelu 4.

Tabulka 12 Matice záměn testovacích dat – model 4

<i>Matice záměn</i>		<i>Predikovaná kategorie</i>		
		<i>NREM</i>	<i>REM</i>	<i>Bdění</i>
<i>Skutečná kategorie</i>	<i>NREM</i>	2079	579	299
	<i>REM</i>	466	224	119
	<i>Bdění</i>	184	80	41



Obrázek 41 Výsledek klasifikace pro testovací data modelu 4


Statistické vyhodnocení modelu 4 je uvedeno v následující tabulce 13. V porovnání dosažených výsledků modelu 4 a modelů 5 a 6, které jsou zmíněny níže, mají všechny modely srovnatelný vývoj výsledků. Ve všech třech případech došlo ke snížení procentuální hodnoty senzitivity a F1 skóre u testovacích dat v porovnání s výsledky na trénovacích datech. Stejně tak ve všech případech došlo u specifity a celkové úspěšnosti ke zvýšení jejich hodnot. Nízké hodnoty by mohly být způsobeny nerovnoměrným zastoupením tří klasifikovaných skupin v testovacích datech a nedostatečnou schopností sítě provést správnou klasifikaci. Všechny hodnoty statistického vyhodnocení byly získány jako průměr z výsledků pro jednotlivé skupiny. Statistické vyhodnocení modelu 4, vztažené vždy jen k jedné klasifikované skupině, je uvedeno v příloze A.3 v tabulce 22 pro bdění, v tabulce 23 pro NREM a v tabulce 24 pro REM.

Tabulka 13 Statistické vyhodnocení modelu 4

	Trénovací data	Testovací data
Senzitivita	40,46 %	35,16 %
Specifita	67,65 %	71,71 %
Celková úspěšnost	62,76 %	68,61 %
F1 skóre	42,84 %	29,30 %


4.4.5 Klasifikace na bdění vs. NREM vs. REM s využitím akcelerometru

Klasifikační model 5 využívá ke klasifikaci na tři skupiny pouze akcelerometrická data. Model má za úkol rozpoznat bdění, NREM a REM fáze. Stejně jako u modelu 2 použitá data neprošla všemi kroky zpracování, jako je uvedeno v kapitole 4.2. Došlo zde k vynechání kroku přípravy pomocí neuronové sítě autoenkodéru, jelikož na vstup sítě nebyly požadovány vektory příznaků získané z výše zmíněné sítě. Do sítě vstupuje vektor, který byl získán přepočtem ze tří os akcelerometru. Vstupem LSTM sítě jsou tedy jednotlivé epochy, kdy jedna obsahuje 1500 pohybových hodnot. Obrázek 42 reprezentuje grafické znázornění použité architektury modelu 5. Síť je tvořena jednou vrstvou, která je složena z 80 jednotek. Následují dvě plně propojené vrstvy, výstupem první z nich je vektor hodnot o délce 35 příznaků. Druhá vrstva má délku 3, z důvodu klasifikace do tří skupin na bdění, NREM a REM fáze.




Obrázek 42 Grafické znázornění použité architektury LSTM modelu 5

Maximální počet epoch, během kterých byl model 5 trénován je 10. Pro učení sítě byl zvolen optimizér Adam. Velikost batche byla nastavena na hodnotu 50. Obrázek 43 zobrazuje grafy popisující průběh učení modelu. Horní graf popisuje hodnotu přesnosti (accuracy) a dolní hodnotu chyby (loss) v závislosti na počtu epoch. V grafu popisujícím celkovou hodnotu přesnosti byla nejvyšší dosažená hodnota přesnosti 44 %. Z průběhu popisujícího chybu lze pozorovat, že k učení sítě docházelo převážně v první epoše.



Obrázek 43 Průběh učení modelu 5

Obrázek 44 zobrazuje graf, ve kterém jsou vykresleny normalizované průběhy akcelerometrických dat. Každý průběh odpovídá jedné epoše, tzn. jeho délka je 30 sekund a počet hodnot je 1500. Legenda popisuje skutečnou/predikovanou fázi spánku, symbol *w* označuje bdění a *s* spánek. Modrá křivka reprezentuje správně klasifikovanou fázi bdění. Z grafu je patrné, že ve fázi bdění došlo k nějakému pohybu. Tento děj je v dané fázi předpokládán, avšak existují i fáze bdění, kdy osoba klidně leží, a tudíž k žádnému pohybu nedochází. Tento případ zobrazuje červený průběh křivky, kdy lze pozorovat pouze malou výchylku, zvýrazněnou pomocí šipky v grafu. Jedná se o fázi bdění, která byla klasifikována jako NREM. Následujícím příkladem uvedeným v grafu je přiřazení skupiny bdění, přestože se jednalo o NREM fázi. Z průběhu je patrné, že zde opravdu došlo k pohybu. Z čehož lze usuzovat, že by se mohlo jednat o Non – REM 1 fázi, ve které se může objevit svalová aktivita, lidově řečeno trhnutí. Poslední ukázkou tvoří REM fáze, která ovšem byla klasifikována jako bdění. V REM fázi se nám zdají sny, dochází k rychlým očním pohybům (zde detekovatelné nejsou) a nepravidelně se mohou objevit i krátké svalové záškuby. Což by vysvětlovalo pohyb reprezentovaný zelenou křivkou.



Obrázek 44 Graf zobrazující průběhy normalizovaného akcelerometru (skutečné/predikované fáze, w – bdělost, NREM – Non REM)

Tabulka 14 obsahuje výsledky klasifikace na trénovacích datech pro model 5. Nejlepší výsledky byly dosaženy pro správné určení NREM fáze. Z celkového počtu 7455 případů bylo správně klasifikováno 5398 epoch. Správné přiřazení REM fáze dosáhlo mírně horších výsledků. Správně určeno bylo 2597 epoch a 3329 jich bylo klasifikováno chybně jako NREM nebo bdění. Nejhůře síť rozeznávala bdění, kdy z celkového počtu 6648 epoch klasifikovala méně než polovinu správně jako bdění, pouze v 2397 případech.

Tabulka 14 Matice záměn trénovacích dat – model 5

Matice záměn		Predikovaná kategorie		
		NREM	REM	Bdění
Skutečná kategorie	NREM	5398	1492	565
	REM	2890	2597	339
	Bdění	3075	1176	2397

Testování na natrénované síti bylo provedeno na 4071 datech. Výsledky klasifikace jsou uvedeny v tabulce 15. Síť se nejlépe naučila rozpoznávat NREM fázi. Počet skutečných NREM, které byly klasifikovány jako REM byl 774 a jako bdění pouze 117. REM byl správně určen ve 157 případech z celkového počtu z 809 případů. Fázi bdění se síti podařilo správně klasifikovat ve 108 případech z celkového počtu 305 epoch. Na obrázku 53 v příloze A.4 je zobrazen výsledek klasifikace pro testovací data modelu 5.

Tabulka 15 Matice záměn testovacích dat – model 5

<i>Matice záměn</i>		<i>Predikovaná kategorie</i>		
		<i>NREM</i>	<i>REM</i>	<i>Bdění</i>
<i>Skutečná kategorie</i>	<i>NREM</i>	2066	774	117
	<i>REM</i>	609	157	43
	<i>Bdění</i>	159	38	108


V tabulce 16 je uvedeno statistické vyhodnocení modelu 5. Na trénovacích datech bylo dosaženo vyšších hodnot u senzitivity (50,17 %) a F1 skóre (55,46 %). U testovacích dat došlo k poklesu obou hodnot, senzitivita 42,41 % a F1 skóre 37,58 %. Všechny hodnoty statistického vyhodnocení byly získány jako průměr z výsledků pro jednotlivé skupiny. Statistické vyhodnocení modelu 5, vztažené vždy jen k jedné klasifikované skupině, je uvedeno v příloze A.4 v tabulce 25, v tabulce 26 a v tabulce 27.

Tabulka 16 Statistické vyhodnocení modelu 5

	Trénovací data	Testovací data
Senzitivita	50,17 %	42,41 %
Specifická	68,44 %	74,35 %
Celková úspěšnost	67,93 %	71,67 %
F1 skóre	55,46 %	37,58 %

4.4.6 Klasifikace na bdění vs. NREM vs. REM s využitím tepové frekvence a akcelerometru

Posledním modelem je model 6, který provádí klasifikaci s využitím tepové frekvence a akcelerometru. Do sítě vstupují epochy, které jsou zastoupeny dvěma řádky, v prvním jsou zaneseny hodnoty tepové frekvence o stejné délce jako je délka epochy, tudíž 30. Ve druhém řádku jsou zaznamenány akcelerometrická data o stejné délce. Celá architektura použité sítě je znázorněna na obrázku 45. Síť je tvořena pouze jednou LSTM vrstvou, která má 40 jednotek. Jako další následuje opět jen jedna plně propojená vrstva. Jejím výstupem je vektor o délce 3, jelikož se jedná o klasifikaci do tří skupin na bdění, NREM a REM. Síť byla trénována na 25 záznamech, které byly rozděleny na trénovací a validační množinu. Samotné trénování probíhalo po dobu 10 epoch. Při nastavení maximálního počtu epoch na více než 10 již nedocházelo k žádným změnám v učení. Pro učení sítě byl zvolen optimizér Adam a velikost batche byla nastavena na hodnotu 65.



Obrázek 45 Grafické znázornění použité architektury LSTM modelu 6

V tabulce 17 jsou výsledky klasifikace na trénovacích datech modelu 6. Nejlepší výsledky byly opět dosaženy při určení NREM fáze. Z celkového počtu 7455 případů bylo správně klasifikováno 4799 epoch. REM fáze byla správně klasifikována v 2020 případech a 3092 bylo klasifikováno chybně jako NREM a 714 epoch jako bdění. Nejhůře se síť naučila rozpoznat bdění, kdy z celkového počtu 6648 epoch klasifikovala správně jako bdění pouze v 1570 případech.

Tabulka 17 Matice záměn trénovacích dat – model 6

<i>Matice záměn</i>		<i>Predikovaná kategorie</i>		
		<i>NREM</i>	<i>REM</i>	<i>Bdění</i>
<i>Skutečná kategorie</i>	<i>NREM</i>	4799	1903	753
	<i>REM</i>	3092	2020	714
	<i>Bdění</i>	3646	1432	1570

Výsledky klasifikace jsou uvedeny v tabulce 18. Nejvíce správně rozpoznaných epoch 2051 bylo rozpoznáno u NREM fáze. Počet NREM, které byly klasifikovány chybně jako REM byl 418 a jako bdění 488. REM fáze byla správně přiřazena ve 166 případech. Chybně jako bdění a NREM bylo klasifikováno 128 a 515 epoch. Fázi bdění se síti podařilo správně klasifikovat pouze ve 88 případech z celkového počtu 305 epoch.

Tabulka 18 Matice záměn testovacích dat – model 6


<i>Matice záměn</i>		<i>Predikovaná kategorie</i>		
		<i>NREM</i>	<i>REM</i>	<i>Bdění</i>
<i>Skutečná kategorie</i>	<i>NREM</i>	2051	418	488
	<i>REM</i>	515	166	128
	<i>Bdění</i>	177	40	88

Statistické vyhodnocení modelu 6 je uvedeno v tabulce 19. Jako u předchozího modelu 5 bylo trénovacích datech dosaženo vyšších hodnot u senzitivity (42,55 %) a F1 skóre (46,84 %) oproti výsledkům na testovacích datech. U výsledků specifcity došlo ke zvýšení z 67,73 % na 71,86 %. Stejně tak došlo ke zlepšení u celkové úspěšnosti (accuracy) z hodnoty 64,02 % na 68,45 %. Všechny hodnoty statistického vyhodnocení byly získány jako průměr z výsledků pro jednotlivé skupiny. Statistické vyhodnocení modelu 6, vztažené vždy jen k jedné klasifikované skupině, je uvedeno v příloze A.5 v tabulce 28, v tabulce 29 a v tabulce 30.

Tabulka 19 Statistické vyhodnocení modelu 6

	Trénovací data	Testovací data
Senzitivita	42,55 %	37,91 %
Specifická	67,73 %	71,86 %
Celková úspěšnost	64,02 %	68,45 %
F1 skóre	46,84 %	30,38 %

Správná klasifikace jednotlivých fází z pohybových dat je velmi složitá, jelikož hned v několika fázích se mohou vyskytovat výraznější pohyby. Prvním příkladem je bdění, které je na obrázku 46 znázorněna modrou barvou (viz. legenda). Druhou fází, ve které byl zaznamenán pohyb, je REM fáze. V grafu je reprezentována oranžovou barvou. Konkrétně tato REM byla označena jako bdění. Vizuální srovnání prvního zmíněného průběhu a průběhu REM ukazuje, že v REM došlo k většímu pohybu než v zobrazené fázi bdění. Proto záměna s fází bdění není v tomto případě moc překvapující. Dalším zajímavým srovnání jsou průběhy fialové a zelené fáze bdění, které byly obě klasifikovány jako REM. Srovnání obou průběhů ukazuje, že se v bdění nemusí vyskytovat dobře nebo vůbec žádný rozeznatelný pohyb. Legenda popisuje skutečnou/predikovanou fázi spánku, symbol *w* označuje bdění a *s* spánek.

**Obrázek 46** Graf zobrazující průběhy normalizovaného akcelerometru (skutečné/predikované fáze, *w* – bdělost, NREM – Non REM)

5. ZHODNOCENÍ VÝSLEDKŮ

Pokročilé skórování spánkových dat bylo realizováno pomocí rekurentní neuronové sítě, konkrétně architektury LSTM. Je to síť hlubokého učení a je založena na metodě učení s učitelem. LSTM síť byla vybrána kvůli své schopnosti naučit se dlouhodobé časové závislosti v signálech. Do sítě vstupovaly jednotlivé epochy, délka trvání jedné epochy je 30 sekund. V rámci praktické části diplomové práce bylo vytvořeno několik klasifikačních modelů. První tři modely prováděly klasifikaci do dvou skupin na spánek a bdění. Následující modely klasifikovaly data do tří skupin na bdění, NREM a REM fázi. Zpracování dat, vytvoření vhodných sítí a ilustrační obrázky a grafy byly vytvořeny v programovém prostředí MATLAB.

Nalezení správné kombinace použitých parametrů nastavení sítě je obtížné. Správnost klasifikace závisí na počtu použitých LSTM vrstev, počtu plně propojených vrstev a na velikosti batche. Nastavení všech použitých sítí jsou nejlepší dosažená. Při snižování velikosti batche klasifikovala síť epochy pouze jako spánek, naopak při jeho zvětšování jako bdění. K učení modelů docházelo převážně jen v průběhu první epochy. Maximální počet epoch byl zvolen na 10, při trénování na větším počtu se hodnoty přesnosti a chyby staly konstantními. V rámci klasifikačních modelů bylo zkoušeno u některých z nich odebrat testovací záznam, s cílem dosáhnout lepších klasifikačních výsledků. S cílem ověření věrohodnosti statistických výsledků byla upravena testovací množina dat, aby obsahovala přibližně stejný počet bdění a spánku. Výsledkem byly identické hodnoty senzitivity a specificity, ale došlo k malé odchylce od výsledků úspěšnosti a F1 skóre.

Ke klasifikaci bylo využito několik parametrů. První model využívá pouze data tepové frekvence, druhý akcelerometrická data. Třetí model využívá oboje, avšak pohybová data prošla jiným procesem zpracování. Samotná akcelerometrická data měla délku 1500 hodnot na epochu. V kombinaci s tepovou frekvencí byla jejich délka 30, stejná jako délka záznamů tepové frekvence. Dosažené výsledky klasifikačních sítí na dvě skupiny jsou uvedeny v tabulce 20. Nejlepších výsledků dosáhl model, který ke klasifikaci využíval pouze akcelerometr. V rámci předzpracování nebyla zmenšena délka jeho záznamů a v jeho epochách byl dobře rozpoznatelný pohyb. Akcelerometrická data předzpracovaná autoenkodérem nejsou vhodná jako samostatný vstupní parametr sítě. Odvozené příznaky nenesou odpovídající pohybovou informaci jako původní data. Tudíž by model 3, využívající tepovou frekvenci a akcelerometr, mohl dosáhnout lepších výsledků při použití vhodně upravených původních akcelerometrických dat, ale jinak, než pomocí autoenkodéru jako tomu bylo zde. Dosažené výsledky klasifikace na spánek a bdění bych zhodnotila kladně, obzvláště překvapující byly výsledky akcelerometru. Lepší výsledky byly očekávány při použití obou parametrů, tepové frekvence i akcelerometru. Vytvořené architektury a nalezená nastavení však stále nemají dostačující výsledky, aby mohly být zařazeny mezi běžně používané metody vhodné pro klasifikaci. Pro porovnání zobrazuje tabulka 1 v kapitole 3.4 přehled několika studií provedených v posledních letech.

Tabulka 20 Porovnání výsledků klasifikace spánku vs. bdění

Použité parametry	LSTM vrstva	Senzitivita [%]	Specifita [%]	Celková úspěšnost [%]	F1 skóre [%]
Tepová frekvence	60/20	64,15	40,66	62,39	75,94
Akcelerometr	64/64	71,06	57,05	70,01	81,42
Tepová frekvence a akcelerometr	74/30	72,04	35,74	69,32	87,99

Ke klasifikaci do tří skupin (viz. tabulka 21) byly využity dva parametry, tepová frekvence a akcelerometr, stejně jako u předchozí klasifikace na spánek a bdění. První model klasifikující do tří skupin využíval tepovou frekvenci, druhý model akcelerometr a třetí model kombinaci obou parametrů. Stejně jako v předchozím případě se hodnoty použité u samostatného akcelerometru a toho v kombinaci s tepovou frekvencí lišily. Klasifikace do tří skupin je oproti klasifikaci do dvou skupin složitější. Hlavním důvodem je velká podobnost tepové frekvence ve fázích bdění a REM. Během bdění jsou hodnoty tepové frekvence vyšší, následně s postupným hlubším spánkem klesají a v REM fázi dochází ke zvýšení tepové frekvence. Podobně jsou na tom data z akcelerometru, kdy se může ve více fázích vyskytnout pohyb, který může být při klasifikaci mezi danými fázemi lehce zaměněn. Najdou se však i takové případy, kdy se ve fázi bdění nevyskytuje žádný pohyb. To pak může opět dojít k chybné klasifikaci na jakoukoli jinou fázi. Nejlepších výsledků dosáhl model, který využíval pouze akcelerometr. Oproti modelu, který klasifikoval na dvě skupiny, došlo v tomto případě k dosažení nižších hodnot u senzitivity a F1 skóre, ale naopak byla zaznamenána vyšší hodnota u specifity. Rozdíl hodnot je ovlivněn klasifikací do většího počtu skupin, která je náročná pro správné odlišení všech tří fází. Velkou nevýhodou využití akcelerometru s neupravenou délkou dat byla dlouhá doba trénování modelu. Celkový výpočetní čas byl cca 4 hodiny. Výpočetní čas ostatních modelů nepřesahoval 1,5 hodiny. Lepších výsledků klasifikace by mohlo být dosaženo nejprve provedením klasifikace na bdění a spánek a poté provedením druhé klasifikace, která bude rozpoznávat NREM a REM. Popřípadě všechny druhy NREM.

Tabulka 21 Porovnání výsledků klasifikace bdění vs. NREM vs. REM

Použité parametry	LSTM vrstva	Senzitivita [%]	Specifická [%]	Celková úspěšnost [%]	F1 skóre [%]
Tepová frekvence	64/64	35,16	71,71	68,61	29,30
Akcelerometr	40	42,41	74,35	71,67	37,58
Tepová frekvence a akcelerometr	80	37,91	71,86	68,45	30,38

Výhodou použití záznamů tepové frekvence a akcelerometru k hodnocení spánkových stádií je v jejich získání. Například pomocí chytrých hodinek stejně jako v této práci. Výhodou hodinek je, že jsou malé a neomezují pacienta při pohybu ani dalších činnostech. Nevýhodou je, že právě tyto výše zmíněná data nejsou zcela vhodná pro klasifikaci spánkových stádií. Důvodem je to, že hodnoty tepové frekvence mohou dosahovat podobných hodnot v REM fázi a bdění. Průměrná tepová frekvence klesá z bdělých stavů do hlubokého spánku, avšak během REM fáze se tepová frekvence zvyšuje. Podobně je to s akcelerometrickými daty, protože s pohybem se můžeme setkat hned v několika fázích. Avšak nebude tomu tak ve všech případech. Pohybovou aktivitu je možné zaznamenat během bdění, kdy se člověk všemožně převaluje a uvelebují před spaním. Během prvního lehkého spánku (Non – REM 1) může dojít k probuzení, které může být způsobeno leknutím a doprovázené zaškrbnutím celého těla nebo některé jeho části. Velkou nevýhodou při použití Apple Watch bylo mnoho epoch, které obsahovaly nedostatečné množství informace. Chyba byla pravděpodobně způsobena při měření dat, kdy naměřené hodnoty nebyly měřeny se zadanou vzorkovací frekvencí. Nebo při jejich ukládání či přenosu na server mohlo dojít ke ztrátě části hodnot z epochy. Kvůli těmto chybám došlo ke zvýšení počtu kroků nutným k předzpracování dat, a tím pádem se prodlužuje i čas zpracování. Kvůli chybějícím datům neobsahuje daná epocha plnohodnotnou informaci, což jistě vede ke snížení kvality detekce spánku.

Získané výsledky jsou z velké části ovlivněny použitou sítí a její architekturou. LSTM síť se řadí mezi rekurentní neuronové sítě hlubokého učení. Síť byla vybrána kvůli své schopnosti naučit se dlouhodobé závislosti v signálech. Což vede k otázce, jestli v datech použitých v této práci, dokázala síť najít nějaký vývoj daného signálu. Proto by bylo zajímavé, vyzkoušet klasifikaci pomocí jiné neuronové sítě, například konvoluční. Při získání srovnatelných výsledků u nové sítě by to znamenalo, že nebyla tak úplně chyba ve vybrané síti, ale že se nejspíš jedná o data nevhodná pro požadovanou klasifikaci. Získání lepších výsledků z nové sítě by dokázalo, že je jistě vhodnější pro danou

klasifikaci. V rámci praktické části této diplomové práce nebyla z časových důvodů provedena klasifikace pomocí jiné neuronové sítě. Funkčnost navržených modelů by mohla být ověřena také provedením testování na jiné spánkové databázi.

Lepších výsledků by mohlo být dosaženo při trénování a následném testování sítě pouze na záznamech od jednoho pacienta. Důvodem je, že hodnoty tepové frekvence nejsou u všech lidí totožné. Rozdíl je také v pohybu, ne každý člověk spí klidně, někdo se během noci hodně převaluje. V rámci mé diplomové práce to nebylo odzkoušeno z důvodu nedostačujícího množství dat od jednoho pacienta.

Druhou variantou spojenou s trénovací a testovací množinou dat je vytvoření nových variant těchto dvou množin ze stávajících záznamů. Výsledkem by mohlo být dosažení lepších trénovacích i testovacích výsledků. Avšak je tu i ta možnost, že by sestavení nových jiných množin výsledky zhoršilo. Důležité je si uvědomit limitace spojené s použitými daty, například že dva záznamy neobsahovaly žádnou REM fázi. Jiným příkladem jsou neúplné záznamy, které nejsou vhodné pro testování sítě.

Jinou možností k dosažení lepších výsledků by mohlo být provedení klasifikace nejprve na bdění a spánek a následně provést rozpoznání spánku na jeho dílčí fáze, například Non – REM1, Non – REM 2, Non – REM 3 a REM. K lepšímu rozpoznání bdění, například u čtení knížky v posteli, by mohlo pomoci přidání snímače okolního osvětlení.

Další možností k dosažení lepší klasifikace by bylo zkombinování s dalším měřicím zařízením. Nejlepší by bylo takové, které dokáže snímat oční pohyby, pomocí kterých by byla upevněna klasifikace REM fáze (např. pomocí kamery pracující v infračervené oblasti). Dalším vhodným doplněním by mohl být jednokanálový elektroencefalografický signál. V tabulce 1 je přehled studie od N. Michielli a spol., kteří využili tento signál (získaný z polysomnografického vyšetření, ne pomocí moderního zařízení) a pomocí LSTM sítě provedli klasifikaci na N1 a REM. Tudíž by zkombinováním několika různých malých zařízení mohlo dojít k dosažení mnohem lepších výsledků než při použití každého zvlášť. Sice by pacient musel nosit více zařízení, ale stále by mohlo být měření pohodlnější oproti klasickému polysomnografickému vyšetření, kde je velké množství různých senzorů a vodičů.

Tabulka 1 v kapitole 3.4. zobrazuje přehled výsledků, zdroje dat a použitých metod u vybraných studií. Z důvodu použití různých zdrojů dat a klasifikací do rozdílných skupin nelze všechny výsledky zcela srovnávat. Přijatelnou variantou pro srovnání je studie G. Jean-Louis a spol., kteří využili jako zdroj dat akcelerometr umístěný na zápěstí. V jejich studii byla taktéž provedena klasifikace do dvou skupin, jako v mé práci. Tudíž lze výsledky nejlepší nalezené sítě, která dosahovala senzitivity 71,06 %, specificity 57,05 %, celkové úspěšnosti 70,01 % a F1 skóre 81,42 %, označit za srovnatelné s výsledky ze studie G. Jean-Louis [10], ve které byly dosažené hodnoty senzitivity 85 % a specificity 54 %.

6. ZÁVĚR

Tato diplomová práce se zabývá pokročilým skórováním spánkových dat. V první části byla provedena literární rešerše zabývající se stručným popisem polysomnografie. Dále obsahuje popis moderních postupů využívajících biomedicínských signálů, které se používají místo polysomnografického vyšetření. Následující kapitola obsahuje popis veřejně dostupných databází spánkových signálů. V další části jsou rozebrány techniky založené na hlubokém učení, které je možné použít pro klasifikaci spánkových dat.

Další část práce se zabývá analýzou dat z Michiganské univerzity ze studie *Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device*. Tato databáze byla vybrána kvůli volnému přístupu k požadovaným signálům. Dalším důvodem výběru bylo to, že obsahuje záznamy ohodnocené expertem, které byly získány z celonočního polysomnografického vyšetření. Studie se zúčastnilo celkem 39 dobrovolníků, kteří obdrželi chytré hodinky Apple Watch, které nosili v průběhu 7 – 14 dnů. Na hodinkách jsou umístěny dva senzory, tříosý MEMS akcelerometr, kterým byly získány informace o pohybu a optický PPG senzor, který byl použitý pro měření tepové frekvence.

V praktické části bylo vytvořeno v programovém prostředí MATLAB šest klasifikačních modelů LSTM sítí. Tři modely prováděly klasifikaci do dvou skupin na spánek a bdění a další tři klasifikovaly data do tří skupin na bdění, NREM a REM. V kapitole 4.4 jsou uvedeny navržené architektury a výsledky klasifikace všech šesti navržených modelů. V případě klasifikace do dvou i tří tříd dosáhl nejlepších výsledků model, který využíval pouze akcelerometr. Model klasifikující spánek vs. bdění byl tvořen dvěma LSTM vrstvami s 64 jednotkami. Dosáhl senzitivity 71,06 %, specificity 57,05 %, celkové úspěšnosti 70,01 % a hodnota F1 skóre byla 81,42 %. Nejlepší model, který prováděl klasifikaci na tři skupiny, bdění, NREM a REM, dosáhl senzitivity 42,41 %, specificity 74,35 %, celkové úspěšnosti 71,67 % a F1 skóre 37,58 %.

Dosažené výsledky klasifikace je možné porovnat s výsledky jiných prací, které jsou uvedeny v kapitole 3.4. V každé uvedené práci došlo ke klasifikování jiných spánkových fází a z jiných datových zdrojů. Avšak dosažené výsledky nejlepšího klasifikačního modelu rozpoznávajícího spánek a bdění jsou srovnatelné s použitými daty, stejným počtem klasifikovaných skupin a s uvedenými výsledky ze studie G. Jean-Louis a kolektivu.

Data z chytrých hodinek, jakožto moderního zařízení pro měření dat, zatím nedosahují potřebných kvalit vhodných pro lékařské využití. Mezi důvody se řadí kvalita zaznamenávaného signálu, vyskytující se artefakty nebo problém s chybějícími záznamy. Při vyřešení těchto problémů a dosažení kvalitního a pravidelného zaznamenávání měřeného signálu by mohly sloužit chytré hodinky a jim podobná moderní zařízení, jako ukazatel kvality spánku pro osobní použití.

LITERATURA

- [1] FIORILLO, Luigi, Alessandro PUIATTI, Michela PAPANDREA et al. Automated sleep scoring: A review of the latest approaches. *Sleep Medicine Reviews* [online]. 2019, 48 [cit. 2020-10-07]. ISSN 10870792. Dostupné z: doi:10.1016/j.smrv.2019.07.007
- [2] MARTIN, Králík, Marina RONZHINA a Miloš BĚLHRAD. Klasifikace spánkových fází pomocí PSG dat. *Elektrorevue* [online]. 2016, 18(6), 193-199 [cit. 2020-10-07]. ISSN 1213-1539. Dostupné z: <http://www.elektrorevue.cz/cz/clanky/zpracovani-signalu/10/klasifikace-spankovych-fazi-pomoci-psg-dat--classification-of-sleep-stages-using-psg-data/>
- [3] JAGOŠOVÁ, Petra. *Analýza polysomnografických dat* [online]. Brno, 2019 [cit. 2020-10-07]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/118307>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Marina Ronzhina.
- [4] NEVŠÍMALOVÁ, Soňa a Karel ŠONKA. *Poruchy spánku a bdění*. 2., dopl. a přeprac. vyd. Praha: Galén, 2007. ISBN 978-80-7262-500-0.
- [5] HAGHAYEGH, Shahab, Sepideh KHOSHNEVIS, Michael H. SMOLENSKY a Kenneth R. DILLER. Application of deep learning to improve sleep scoring of wrist actigraphy. *Sleep Medicine* [online]. 2020, 74(235-241), 235-241 [cit. 2020-10-07]. ISSN 13899457. Dostupné z: doi:10.1016/j.sleep.2020.05.008
- [6] DE ZAMBOTTI, MASSIMILIANO, NICOLA CELLINI, AIMÉE GOLDSTONE, IAN M. COLRAIN a FIONA C. BAKER. Wearable Sleep Technology in Clinical and Research Settings. *HHS Public Access* [online]. 2019, 51(7), 1538-1557 [cit. 2020-10-12]. ISSN 0195-9131. Dostupné z: doi:10.1249/MSS.0000000000001947
- [7] Muse2. *Muse* [online]. Toronto ON, Canada: InteraXon, 2021 [cit. 2021-4-22]. Dostupné z: <https://choosemuse.com/>
- [8] ANCOLI-ISRAEL, Sonia, Roger COLE, Cathy ALESSI, Mark CHAMBERS, William MOORCROFT a Charles P. POLLAK. The Role of Actigraphy in the Study of Sleep and Circadian Rhythms. *Sleep* [online]. 2003, 26(3), 342-392 [cit. 2020-10-13]. ISSN 0161-8105. Dostupné z: doi:10.1093/sleep/26.3.342
- [9] ATHAVALLE, Yashodhan a Sridhar KRISHNAN. Biosignal monitoring using wearables: Observations and opportunities. *Biomedical Signal Processing and Control* [online]. 2017, 38(22-33), 22-33 [cit. 2020-10-13]. ISSN 17468094. Dostupné z: doi:10.1016/j.bspc.2017.03.011
- [10] JEAN-LOUIS, Girardin, Daniel F KRIPKE, Roger J COLE, Joseph D ASSMUS a Robert D LANGER. Sleep detection with an accelerometer actigraph: comparisons with polysomnography. *Physiology & Behavior* [online]. 2001, 72(1-2), 21-28 [cit. 2020-10-13]. ISSN 00319384. Dostupné z: doi:10.1016/S0031-9384(00)00355-3

- [11] RADHA, Mustafa, Pedro FONSECA, Arnaud MOREAU, Marco ROSS, Andreas CERNY, Peter ANDERER, Xi LONG a Ronald M. AARTS. Sleep stage classification from heart-rate variability using long short-term memory neural networks. *Scientific Reports* [online]. 2019, 9(1) [cit. 2020-10-13]. ISSN 2045-2322. Dostupné z: doi:10.1038/s41598-019-49703-y
- [12] MILLER, Christopher B., Simon D. KYLE, Kerri L. MELEHAN a Delwyn J. BARTLETT. Methodology for the Assessment of Sleep. *Sleep and Affect* [online]. Elsevier, 2015, , 65-90 [cit. 2020-10-22]. ISBN 9780124171886. Dostupné z: doi:10.1016/B978-0-12-417188-6.00004-9
- [13] WANG, Lei, Youfang LIN a Jing WANG. A RR interval based automated apnea detection approach using residual network. *Computer Methods and Programs in Biomedicine* [online]. 2019, 176, 93-104 [cit. 2020-10-22]. ISSN 01692607. Dostupné z: doi:10.1016/j.cmpb.2019.05.002
- [14] BENJAMIN, Beatrice R., Mathias VALSTAD, Torbjørn ELVSÅSHAGEN et al. Heart rate variability is associated with disease severity in psychosis spectrum disorders. *Progress in Neuro-Psychopharmacology and Biological Psychiatry* [online]. 2020, 152020(110108), 1-8 [cit. 2020-10-22]. ISSN 02785846. Dostupné z: doi:10.1016/j.pnpbp.2020.110108
- [15] CASAL, Ramiro, Leandro E. DI PERSIA a Gastón SCHLOTTHAUER. Classifying sleep–wake stages through recurrent neural networks using pulse oximetry signals. *Biomedical Signal Processing and Control* [online]. 2021, 63(102195), 1-8 [cit. 2020-10-22]. ISSN 17468094. Dostupné z: doi:10.1016/j.bspc.2020.102195
- [16] O'REILLY, Christian, Nadia GOSSELIN, Julie CARRIER a Tore NIELSEN. Montreal Archive of Sleep Studies: an open-access resource for instrument benchmarking and exploratory research. *Journal of Sleep Research* [online]. 2014, 23(6), 628-635 [cit. 2021-4-25]. ISSN 09621105. Dostupné z: doi:10.1111/jsr.12169
- [17] GOLDBERGER, A., L. AMARAL, L. GLASS, J. HAUSDORFF, P. C. IVANOV, R. MARK a H. E. STANLEY. Components of a new research resource for complex physiologic signals. *PhysioBank, PhysioToolkit, and PhysioNet* [online]. 2000, 101(23), e215-e220 [cit. 2021-5-2]. Dostupné z: <https://physionet.org/content/sleep-edfx/1.0.0/>
- [18] KEMP, B, AH ZWINDERMAN, B TUK, HAC KAMPHUISEN a JLL OBERYÉ. *Analysis of sleep-dependent neuronal feedback loop: the slow wave microcontinuity of the EEG* [online]. 2000, IEEE-BME 47(9), 1185-1194 [cit. 2021-5-2]. Dostupné z: <https://physionet.org/content/sleep-edfx/1.0.0/>
- [19] WALCH, Olivia, Yitong HUANG, Daniel FORGER a Cathy GOLDSTEIN. Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device. *Sleep* [online]. 2019, 42(12), 1-19 [cit. 2020-11-04]. ISSN 0161-8105. Dostupné z: doi:10.1093/sleep/zsz180

- [20] ROSSI, Alessio, Eleonora DA POZZO, Dario MENICAGLI, et al. A Public Dataset of 24-h Multi-Levels Psycho-Physiological Responses in Young Healthy Adults. *Data* [online]. 2020, 5(4) [cit. 2021-5-2]. ISSN 2306-5729. Dostupné z: doi:10.3390/data5040091
- [21] Deep learning vs. signály a časové řady. In: *SCIENCEmag.cz* [online]. HUMUSOFT, 2019 [cit. 2021-01-02]. Dostupné z: <https://sciencemag.cz/deep-learning-vs-signaly-a-casove-rady/>
- [22] CHOLLET, François. *Deep learning v jazyku Python: knihovny Keras, Tensorflow*. První vydání. Praha: Grada Publishing, 2019. Knihovna programátora (Grada). ISBN ISBN978-80-271-2750-4.
- [23] VOLNÁ, Eva. *Evoluční algoritmy a neuronové sítě* [online]. Ostrava, 2012 [cit. 2020-10-28]. Dostupné z: http://physics.ujep.cz/~mmaly/vyuka/MPVT_II/Heuristiky/SOMAdetail-Evolucni_algoritmy_a_neuronove_site+Genetika.pdf. Skripta. Ostravská univerzita.
- [24] MAIER, Andreas, Christopher SYBEN, Tobias LASSER a Christian RIESS. A gentle introduction to deep learning in medical image processing. *Zeitschrift für Medizinische Physik* [online]. 2019, 29(2), 86-101 [cit. 2020-10-28]. ISSN 09393889. Dostupné z: doi:10.1016/j.zemedi.2018.12.003
- [25] Biological neuron model. In: *Artificial intelligence* [online]. The University of AI, 2020 [cit. 2020-10-28]. Dostupné z: <https://exploreai.org/p/introduction-to-deep-learning>
- [26] ŠÍMA, Jiří a Roman NERUDA. *Teoretické otázky neuronových sítí*. První vydání. Praha: MATFYZPRESS, 1996. ISBN 80-858-6318-9.
- [27] SAHA, Sumit. A Comprehensive Guide to Convolutional Neural Networks. *Towards data science: A Medium publication sharing concepts, ideas, and codes*. [online]. 2015 [cit. 2020-11-24]. Dostupné z: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>
- [28] Convolution layer. In: *Stanford* [online]. [cit. 2020-12-11]. Dostupné z: <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-convolutional-neural-networks>
- [29] YAMASHITA, Rikiya, Mizuho NISHIO, Richard Kinh Gian DO a Kaori TOGASHI. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging* [online]. 2018, 9(4), 611-629 [cit. 2020-12-11]. ISSN 1869-4101. Dostupné z: doi:10.1007/s13244-018-0639-9
- [30] GAMAL, Eslam. What is the ReLU layer in CNN? In: Quora [online]. 7. 5. 2020 [cit. 2020-12-02]. Dostupné z: <https://www.quora.com/What-is-the-ReLULayer-in-CNN>
- [31] Fully Connected Layer. In: *Towards data science* [online]. 2018 [cit. 2020-12-11]. Dostupné z: <https://towardsdatascience.com/convolutional-neural-network-17fb77e76c05>

- [32] SRIVASTAVA, Nitish, Geoffrey HINTON, Alex KRIZHEVSKY, Ilya SUTSKEVER a Ruslan SALAKHUTDINOV. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research* [online]. 2014, 15(56), 1929-1958 [cit. 2020-12-02]. Dostupné z: <http://jmlr.org/papers/v15/srivastava14a.html>
- [33] KIRANYAZ, Serkan, Onur AVCI, Osama ABDELJABER, Turker INCE, Moncef GABBOUJ a Daniel J. INMAN. 1D Convolutional Neural Networks and Applications: A Survey [online]. 2019, 9 May 2019, 1-20 [cit. 2020-12-11]. Dostupné z: <https://arxiv.org/abs/1905.03554>
- [34] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. *Deep learning*. Cambridge: MIT Press, [2016]. Adaptive computation and machine learning (MIT Press). ISBN 978-026-2035-613.
- [35] OLAH, Christopher. *Understanding LSTM Networks* [online]. In: . 2015-08-27, s. 1 [cit. 2020-11-18]. Dostupné z: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [36] PHI, Michael. Illustrated Guide to LSTM's and GRU's: A step by step explanation. *Towards data science* [online]. 2018 [cit. 2020-12-13]. Dostupné z: <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>
- [37] LAI, Ying-Chih, Chin-Chia CHANG, Chia-Ming TSAI, Shih-Ching HUANG a Kai-Wei CHIANG. A Knowledge-Based Step Length Estimation Method Based on Fuzzy Logic and Multi-Sensor Fusion Algorithms for a Pedestrian Dead Reckoning System. *ISPRS International Journal of Geo-Information* [online]. 2016, 5(5) [cit. 2021-04-13]. ISSN 2220-9964. Dostupné z: doi:10.3390/ijgi5050070
- [38] UÇAR, Muhammed Kürşad, Mehmet Recep BOZKURT, Cahit BILGIN a Kemal POLAT. Automatic sleep staging in obstructive sleep apnea patients using photoplethysmography, heart rate variability signal and machine learning techniques. *Neural Computing and Applications* [online]. 2018, 29(8), 1-16 [cit. 2020-12-26]. ISSN 0941-0643. Dostupné z: doi:10.1007/s00521-016-2365-x
- [39] BERKA, Petr. *Dobývání znalostí z databází*. Praha: Academia, 2003. ISBN 80-200-1062-9
- [40] MICHIELLI, Nicola, U. Rajendra ACHARYA a Filippo MOLINARI. Cascaded LSTM recurrent neural network for automated sleep stage classification using single-channel EEG signals. *Computers in Biology and Medicine* [online]. 2019, 106, 71-81 [cit. 2021-5-4]. ISSN 00104825. Dostupné z: doi:10.1016/j.combiomed.2019.01.013

SEZNAM SYMBOLŮ A ZKRATEK

Zkratky:


AASM	Americká akademie spánkové medicíny
CNN	Konvoluční neuronová síť (Convolutional neural network)
EEG	Elektroencefalogram
EKG	Elektrokardiogram
EMG	Elektromyogram
EOG	Elektrookulogram
HRV	Variabilita srdečního rytmu (heart-rate variability)
Hz	Hertz
LSTM	Long Short Term Memory
m	Metr
Non-REM	Fáze spánku (Non Rapid Eye Movement)
PSG	Polysomnografie
QRS	Komorový komplex
RELU	Rectified linear unit
REM	Fáze spánku (Rapid Eye Movement)
RNN	Rekurentní neuronová síť (Recurrent neural network)
S	Spánek (Sleep)
s	Sekunda
subEMG	Submentální EMG
SVM	Signal Vector Magnitude
W	Bdělost (Wake)

SEZNAM PŘÍLOH


PŘÍLOHA A - KLASIFIKACE SPÁNKOVÝCH STÁDIÍ.....	71
---	-----------

Příloha A - Klasifikace spánkových stádií


A.1 Klasifikace spánek vs. bdění s využitím tepové frekvence




Obrázek 47 Výsledek klasifikace pro testovací data na modelu 1 pro šest záznamů



Obrázek 48 Výsledek klasifikace pro testovací data modelu 1 pro 1 záznam

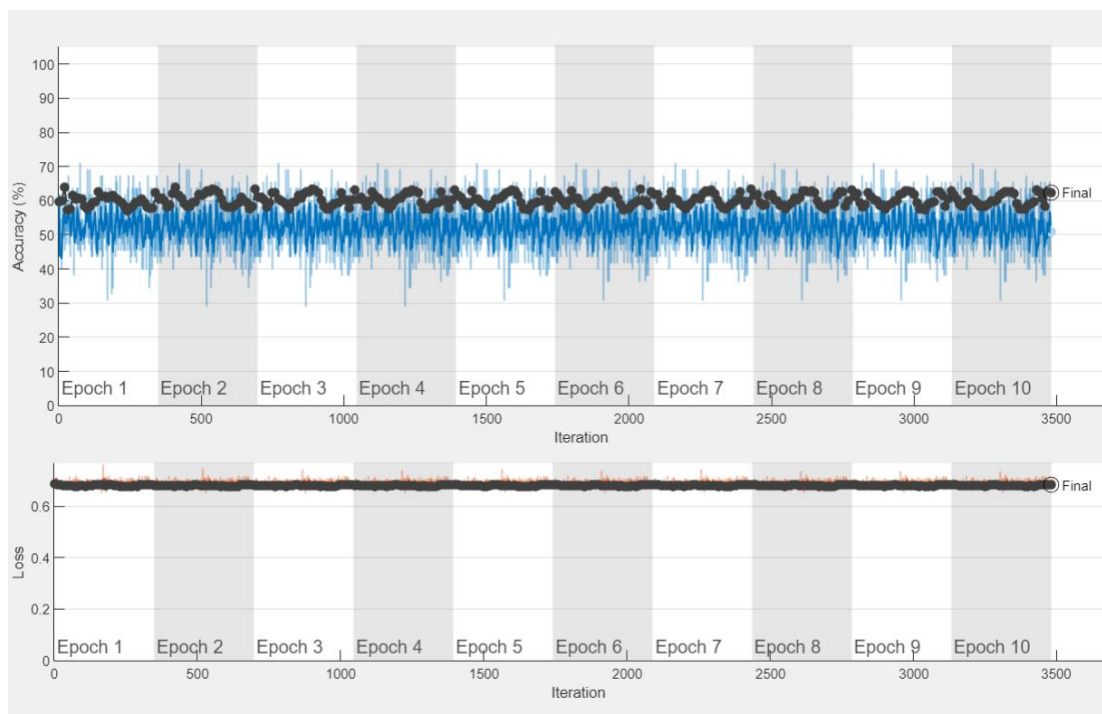


Obrázek 49 Výsledek klasifikace pro testovací data modelu 1 pro 1 záznam




Obrázek 50 Výsledek klasifikace pro testovací data modelu 1 pro 1 záznam

A.2 Klasifikace spánku vs. bdění s využitím tepové frekvence a akcelerometru



Obrázek 51 Průběh učení modelu 3



Obrázek 52 Výsledek klasifikace pro testovací data modelu 3 pro všechny záznamy

A.3 Klasifikace bdění vs. NREM vs. REM s využitím tepové frekvence

Tabulka 22 Statistické vyhodnocení modelu 4 - **bdění**

	Trénovací data	Testovací data
Senzitivita	11,63 %	13,44 %
Specifická	90,26 %	88,90 %
Celková úspěšnost	64,03 %	83,25 %
F1 skóre	17,74 %	10,73 %


Tabulka 23 Statistické vyhodnocení modelu 4 - **NREM**

	Trénovací data	Testovací data
Senzitivita	70,31 %	64,36 %
Specifická	41,65 %	46,44 %
Celková úspěšnost	62,47 %	53,14 %
F1 skóre	73,13 %	50,68 %

Tabulka 24 Statistické vyhodnocení modelu 4 - **REM**

	Trénovací data	Testovací data
Senzitivita	39,44 %	27,69 %
Specifická	71,03 %	79,80 %
Celková úspěšnost	61,79 %	69,44 %
F1 skóre	37,64 %	26,48 %

A.4 Klasifikace bdění vs. NREM vs. REM s využitím akcelerometru



Obrázek 53 Výsledek klasifikace pro testovací data modelu 5

Tabulka 25 Statistické vyhodnocení modelu 5 - **bdění**

	Trénovací data	Testovací data
Senzitivita	36,06 %	35,41 %
Specifická	93,19 %	95,75 %
Celková úspěšnost	74,13 %	91,23 %
F1 skóre	48,19 %	37,70 %

Tabulka 26 Statistické vyhodnocení modelu 5 - **NREM**

	Trénovací data	Testovací data
Senzitivita	69,87 %	72,41 %
Specifická	31,06 %	52,18 %
Celková úspěšnost	59,25 %	59,75 %
F1 skóre	71,35 %	57,37 %

Tabulka 27 Statistické vyhodnocení modelu 5 - REM

	Trénovací data	Testovací data
Senzitivita	44,58 %	19,41 %
Specifická	81,08 %	75,11 %
Celková úspěšnost	70,14 %	64,04 %
F1 skóre	46,83 %	17,66 %

A.5 Klasifikace bdění vs. NREM vs. REM s využitím tepové frekvence a akcelerometru

Tabulka 28 Statistické vyhodnocení modelu 6 - bdění

	Trénovací data	Testovací data
Senzitivita	23,62 %	28,85 %
Specifická	88,95 %	83,96 %
Celková úspěšnost	67,16 %	79,54 %
F1 skóre	32,42 %	17,44 %

Tabulka 29 Statistické vyhodnocení modelu 6 - NREM

	Trénovací data	Testovací data
Senzitivita	69,36 %	64,37 %
Specifická	37,88 %	45,98 %
Celková úspěšnost	60,75 %	52,86 %
F1 skóre	71,96 %	50,54 %

Tabulka 30 Statistické vyhodnocení modelu 6 - **REM**

	Trénovací data	Testovací data
Senzitivita	34,67 %	20,52 %
Specifická	76,35 %	85,96 %
Celková úspěšnost	64,17 %	72,96 %
F1 skóre	36,13 %	23,17 %